



 **Universität Trier**

Bernhard Baltes-Götz

Statistisches Praktikum mit IBM SPSS Statistics 21 für Windows

2013 (Rev. 131011)

Herausgeber: Zentrum für Informations-, Medien- und Kommunikationstechnologie (ZIMK)
an der Universität Trier
Universitätsring 15
D-54286 Trier
WWW: <http://www.uni-trier.de/index.php?id=518>
E-Mail: zimk@uni-trier.de
Tel.: (0651) 201-3417, Fax.: (0651) 3921

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

Copyright © 2013; ZIMK

Vorwort

Das seit Jahrzehnten bewährte und ständig aktualisierte Statistikprogramm **SPSS** (*Statistical Package for the Social Sciences*) wurde im Jahr 2008 umbenannt in **PASW** (*Predictive Analytics Software*), um wenige Monate später (nach Übernahme des Herstellers durch die Firma IBM) wieder den alten Namen zu erhalten. Genau genommen lautet der aktuelle Name **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, MacOS, Windows). Im Vergleich zu alternativen Statistikprogrammen (z.B. R, SAS, Stata) sind vor allem die folgenden Pluspunkte von SPSS zu nennen (vgl. München 2013):

- Einfache Anwendung
- Gute Unterstützung durch die Statistikliteratur und frei verfügbare Anleitungen
- Gute Erweiterbarkeit und entsprechend zahlreich vorhandene Lösungen (Makros etc.)
- Hohe Nachfrage auf dem Arbeitsmarkt

In Bezug auf die freie Statistik-Programmiersprache R setzt IBM SPSS übrigens nicht auf Abgrenzung, sondern auf eine Integrationslösung, die zu einem funktionalen Gespann aus SPSS und R führt (siehe Baltes-Götz 2013a).

Im vorliegenden Manuskript wird ein Einblick in die statistische Datenanalyse mit der SPSS-Version 21 für Windows vermittelt. Wesentliche Teile des Manuskripts sind wegen der weitgehend konsistenten Bedienungslogik auch für andere SPSS-Versionen unter Windows oder alternativen Betriebssystemen verwendbar.

Dieses Manuskript dient primär als Begleitlektüre zum Kurs *Statistisches Praktikum mit SPSS Statistics* am *Zentrum für Informations-, Medien- und Kommunikationstechnologie* (ZIMK) an der Universität Trier, kann jedoch auch im Selbststudium verwendet werden. Dass dabei die meisten Themen in konkreter Arbeit am Rechner nachvollzogen werden sollten, folgt aus der Kurskonzeption:

Zielgruppe/Voraussetzungen

Der Kurs ist konzipiert für Personen, die *in wesentlichem Umfang* bei Forschungsarbeiten mit SPSS mitwirken wollen, also z.B. im Rahmen einer Abschlussarbeit die Durchführung einer eigenen Studie planen oder bereits begonnen haben. 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.¹

Im Kurs wird eine *methodologische Grundausbildung* (empirische Forschung, Statistik) vorausgesetzt, wie sie üblicherweise in den Studiengängen empirisch-statistisch forschender Disziplinen vermittelt wird.

An EDV-Voraussetzungen werden nur elementare Fertigkeiten im Umgang mit PCs unter Windows erwartet.

¹ 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).

Kursinhalte

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 in knapper Form behandelt, doch kann damit eher vorhandenes Wissen aufgefrischt als neues erworben werden. Insbesondere kann die Anwendung und Diskussion der vielfältigen *statistischen Auswertungsmethoden* nur *exemplarisch* stattfinden. Eine gründliche Behandlung ist nur bei wenigen, besonders häufig eingesetzten Verfahren möglich (z.B. bei der Kreuztabellenanalyse). Insgesamt sollte es im Kurs bzw. Manuskript gelingen, *zentrale Denk- und Arbeitsweisen* der statistisch-empirischen Forschung zu vermitteln.

Zu vielen Auswertungsmethoden bietet das ZIMK Spezialveranstaltungen 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 \(ZIMK\)](#) > [Infos für Studierende](#) > [Kursangebot](#)

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

[IT-Services \(ZIMK\)](#) > [Infos für Studierende](#) > [EDV-Dokumentationen](#) > [Statistik](#)

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 und Modifikation der Daten bis zur statistischen Auswertung und zur Verwertung der Ergebnisse durchgeführt.

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.

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 \(ZIMK\)](#) > [Infos für Studierende](#) > [EDV-Dokumentationen](#) >
[Statistik](#) > [Statistisches Praktikum mit SPSS für Windows](#)

Leser(innen) im Selbststudium können mit den zur Verfügung gestellten Dateien alle Arbeitsschritte im Beispielprojekt des Kurses ab der Datenprüfung konkret durchführen.

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

Inhaltsverzeichnis

Vorwort	III
1 Von der Theorie zu den SPSS-Variablen	1
1.1 Statistik und EDV als Hilfsmittel der Forschung	1
1.1.1 Kluge Entscheidungen trotz Unsicherheit	1
1.1.2 Statistische Methoden	1
1.1.1.1 Parameterschätzung	1
1.1.1.2 Hypothesenprüfung	2
1.1.1.3 Modellierung	3
1.1.3 Lügen	4
1.1.4 Keine statistische Praxis ohne EDV	4
1.2 Planung und Durchführung einer empirischen Untersuchung im Überblick	5
1.2.1 Forschungsziele, Hypothesen und Modelle	5
1.2.2 Datenquellen	5
1.2.3 Untersuchungsplanung	6
1.2.3.1 Festlegung der Beobachtungseinheit(en) und der zu untersuchenden Merkmale	6
1.2.3.2 Entscheidung für ein Untersuchungsdesign	7
1.2.3.3 Operationalisierung der zu untersuchenden Merkmale	7
1.2.3.4 Empirisch prüfbare Hypothesen (über Modellparameter) formulieren	8
1.2.3.5 Statistisches Entscheidungsverfahren	8
1.2.3.6 Stichprobenrekrutierung	8
1.2.3.7 Datendeklaration und Kodierplan	8
1.2.4 Durchführung der Studie inklusive Datenerhebung	9
1.2.5 Datenerfassung und -prüfung	9
1.2.6 Datentransformation	9
1.2.7 Statistische Datenanalyse	10
1.3 Untersuchungsplanung für das Demonstrationsprojekt	10
1.3.1 Die allgemeinspsychologische KFA-Hypothese	10
1.3.2 Untersuchungsplanung	10
1.3.2.1 Beobachtungseinheiten, Merkmale, Design und Operationalisierung	10
1.3.2.2 Formulierung und Illustration des empirisch prüfbaren Hypothese	11
1.3.2.3 Entscheidungsverfahren	12
1.3.2.4 Stichprobenumfangsplanung	13
1.3.3 Eine differentialpsychologische Hypothese	16
1.3.4 Demographische Merkmale	19
1.3.5 Zu Übungszwecken erhobene Merkmale	20
1.3.6 Der Fragebogen	20
1.4 Strukturierung und Kodierung der Daten	22
1.4.1 Fälle und Merkmale in SPSS	22
1.4.2 Strukturierung	23
1.4.2.1 Variablen zur Fallidentifikation	23
1.4.2.2 Abgeleitete Variablen gehören nicht in den Kodierplan	24
1.4.2.3 Mehrfachwahlfragen	24
1.4.2.3.1 Vollständige Sets aus dichotomen Variablen	24
1.4.2.3.2 Sparsame Sets aus kategorialen Variablen	25
1.4.2.4 Offene Fragen	26
1.4.3 Kodierung	27
1.4.3.1 Die wichtigsten Variablentypen in SPSS	27
1.4.3.2 Das Problem fehlender Werte	28
1.4.3.2.1 Benutzerdefinierte MD-Indikatoren	28
1.4.3.2.2 System-Missing (SYSMIS)	29
1.4.3.2.3 Fehlende Werte bei Mehrfachwahl-Fragen und offenen Fragen	29
1.4.3.2.4 Vereinfachung der Erfassung durch Datentransformationstechniken	30
1.4.3.3 Fehlerquellen bei der manuellen Datenerfassung minimieren	32
1.4.3.4 SPSS-Variablennamen	32
1.4.3.5 Kodierplan	33

1.5	Durchführung der Studie (inklusive Datenerhebung)	35
2	Einstieg in SPSS für Windows	36
2.1	SPSS-Produkte an der Universität Trier	36
2.2	Programmstart und Benutzeroberfläche	37
2.2.1	SPSS starten	37
2.2.2	Die wichtigsten SPSS-Fenster	38
2.2.3	Was man mit SPSS so alles machen kann	39
2.3	Das Hilfesystem	39
2.3.1	Systematische Informationen	40
2.3.2	Gezielte Suche nach Begriffen	40
2.3.3	Kontextsensitive Hilfe zu den Dialogboxen	40
2.3.4	Lernprogramm	40
2.3.5	Fallstudien	41
2.3.6	Statistik-Assistent	42
2.4	Weitere Informationsquellen	42
2.4.1	Handbücher und Manuskripte	42
2.4.2	SPSS im Internet	43
2.4.3	ZIMK - Service-Punkte	43
2.5	SPSS für Windows beenden	43
3	Datenerfassung und SPSS-Dateneditor	44
3.1	Methoden zur Datenerfassung	44
3.1.1	Automatisierte Verfahren	44
3.1.1.1	Online-Datenerhebung	44
3.1.1.2	Automatisches Einscannen von schriftlichen Untersuchungsdokumenten	46
3.1.2	Manuelle Verfahren	46
3.1.2.1	Datenerfassung nach einer Papier-gestützten Datenerhebung	46
3.1.2.2	Interviews mit sofortiger Datenerfassung	47
3.2	Erfassung mit dem SPSS-Dateneditor	47
3.2.1	Dateneditor, Datenblatt und Arbeitsdatei	48
3.2.2	Variablen definieren	49
3.2.2.1	Das Datenfenster-Registerblatt Variablenansicht	50
3.2.2.2	Die SPSS-Variablenattribute	50
3.2.2.3	Variablendefinition durchführen	53
3.2.2.4	Variablen einfügen, löschen oder verschieben	56
3.2.2.4.1	Variablen einfügen	56
3.2.2.4.2	Variablen löschen	57
3.2.2.4.3	Variablen verschieben	57
3.2.2.5	Attribute auf andere Variablen übertragen	57
3.2.2.5.1	Variablendeklaration vervielfältigen	57
3.2.2.5.2	Alle Attribute einer Variablen auf andere Variablen übertragen	58
3.2.2.5.3	Einzelne Attribute einer Variablen auf andere Variablen übertragen	59
3.2.2.5.4	Übung	59
3.2.2.6	Numerische Kodierung auch bei nominalskalierten Merkmalen	59
3.2.2.6.1	Wertelabels vereinbaren	59
3.2.2.6.2	Übung	60
3.2.3	Sichern eines Datenblatts als SPSS-Datendatei	60
3.2.4	Rohdatendatei, Transformationsprogramm und Fertigdatendatei	63
3.2.5	Dateneingabe	64
3.2.6	Daten korrigieren	65
3.2.6.1	Wert einer Zelle ändern	65
3.2.6.2	Einen Fall einfügen	65
3.2.6.3	Einen Fall löschen	66
3.2.6.4	Fälle verschieben	66
3.2.7	Weitere Möglichkeiten des Dateneditors	66
3.2.8	Übung	66

4	Univariate Verteilungs- und Fehleranalysen	68
4.1	Fehlerhafte Werte aufspüren	68
4.1.1	Suche nach unzulässigen Werten	69
4.1.2	Einzelprüfung aller Werte	69
4.2	Öffnen von Datendateien	70
4.2.1	SPSS-Datendateien	71
4.2.2	Andere Formate	71
4.3	Verteilungsanalysen für kategoriale Variablen	71
4.4	Arbeiten mit dem Ausgabefenster (Teil I)	77
4.4.1	Arbeiten im Navigationsbereich	77
4.4.1.1	Fokus positionieren	77
4.4.1.2	Ausgabeblocke bzw. Teilausgaben aus- oder einblenden	78
4.4.1.3	Ausgabeblocke oder Teilausgaben markieren	78
4.4.1.4	Ausgabeblocke oder Teilausgaben löschen oder verschieben	78
4.4.2	Viewer-Dokumente drucken	78
4.4.3	Ausgaben sichern und öffnen	79
4.4.4	Objekte via Zwischenablage in andere Anwendungen übertragen	79
4.4.5	Ausgaben exportieren	81
4.4.6	Mehrere Ausgabefenster verwenden	82
4.4.7	Übung	82
4.5	Verteilungsanalysen für metrische Merkmale	82
4.5.1	Maße der zentralen Tendenz	83
4.5.2	Streuungsmaße	84
1.1.5	Schiefen und Wölbung	84
4.5.2.1	Schiefen	84
4.5.2.2	Wölbung (Kurtosis)	85
4.5.2.3	Übung	86
4.5.3	Diskussion ausgewählter Ergebnisse	87
4.6	Übung	88
4.7	Suche nach Daten	89
4.8	Populationsanteil einer Kategorie und Vertrauensintervall	90
4.8.1	Vertrauensintervall verstehen und näherungsweise berechnen	91
4.8.2	Exaktes Vertrauensintervall von SPSS berechnen lassen	93
4.8.3	Stichprobenumfang für eine gewünschte Präzision berechnen	97
5	Speichern der SPSS-Kommandos zu wichtigen Anweisungsfolgen	100
5.1	Zur Motivation	100
5.2	Dialogunterstützte Erstellung von SPSS-Programmen	102
5.3	Arbeiten mit dem Syntax-Fenster	107
5.4	Elementare Regeln zur SPSS-Syntax	108
6	Datentransformation	111
6.1	Vorbemerkungen	111
6.1.1	Transformationsprogramm	111
6.1.2	Datensicherheit	112
6.1.3	Initialisierung neuer numerischer Variablen	113
6.2	Alte Werte einer Variablen auf neue abbilden (Umkodieren)	114
6.2.1	Das praktische Vorgehen am Beispiel einer Gruppenbildung	114
6.2.2	Technische Details	117
6.2.3	Übungen	119
6.2.4	Visuelles Klassieren	120
6.3	Zur Rolle des EXECUTE-Kommandos	123

6.4	Berechnung von Variablen nach mathematischen Formeln	124
6.4.1	Beispiel	124
6.4.2	Technische Details	126
6.4.2.1	Numerische Funktionen	127
6.4.2.2	Regeln für die Bildung numerischer Ausdrücke	129
6.4.2.3	Sonstige Hinweise	130
6.4.3	Übungen	131
6.5	Bedingte Datentransformation	132
6.5.1	Beispiel	132
6.5.2	Bedingungen formulieren	135
6.5.2.1	Vergleich	135
6.5.2.2	Logischer Ausdruck	135
6.5.2.3	Regeln für die Auswertung logischer Ausdrücke	136
6.5.3	Übung	137
6.6	Häufigkeit bestimmter Werte bei einem Fall ermitteln	137
6.7	Erstellung der Fertigdatendatei mit dem Transformationsprogramm	139
6.7.1	Transformationsprogramm vervollständigen	139
6.7.2	Transformationsprogramm ausführen	143
7	Prüfung der zentralen Projekt-Hypothesen	145
7.1	Grundprinzipien des statistischen Hypothesentests	145
7.1.1	Gerichtete Hypothese über den Ärgerzuwachs	145
7.1.2	Voraussetzungen für die Herleitung eines Hypothesentests	145
7.1.6	Teststatistik	145
7.1.2.1	Anforderungen	145
7.1.2.2	Die Prüfgröße zum t-Test für abhängige Stichproben	146
7.1.3	Überschreitungswahrscheinlichkeit und Entscheidungsregel	147
7.1.4	Kritischer Wert und Ablehnungsbereich	147
7.1.5	Das akzeptierte Risiko erster Art	148
7.1.6	Einflussgrößen auf das Risiko zweiter Art	148
7.1.7	Das zweiseitige Testproblem	150
7.1.8	Einseitige Überschreitungswahrscheinlichkeit aus der zweiseitigen bestimmen	151
7.2	Teststatistik und Annahmen im Modell der bivariaten linearen Regression	151
7.2.1	Teststatistik	151
7.2.2	Annahmen	152
7.2.2.1	Linearität	152
7.2.2.2	Normalität der Residuen	153
7.2.2.3	Varianzhomogenität der Residuen	153
7.2.2.4	Unkorreliertheit der Residuen	153
7.3	Verteilungsanalyse für die abgeleiteten Variablen	153
7.3.1	Diagnose von Ausreißern	154
7.3.2	Die SPSS-Prozedur zur explorativen Datenanalyse	155
7.3.3	Ergebnisse für AERGZ	156
7.3.4	Ergebnisse für LOT, AERGAM und BMI	159
7.4	Prüfung der differentialpsychologischen Hypothese	160
7.4.1	Regression von AERGAM auf LOT	160
7.4.2	Methodologische Anmerkungen	163
7.4.2.1	Explorative Analysen im Anschluss an einen „gescheiterten“ Hypothesentest	163
7.4.2.2	Post hoc - Poweranalyse	163
7.4.2.3	Fehlende Werte	165
7.5	Prüfung der KFA-Hypothese	166
7.6	Übung	168

7.7	Arbeiten mit dem Ausgabefenster (Teil II)	169
7.7.1	Pivot-Editor starten	169
7.7.2	Dimensionen verschieben	171
7.7.3	Gruppierungen	172
7.7.4	Kategorien aus- bzw. einblenden, verschieben oder vertauschen	175
7.7.5	Zellen modifizieren	176
7.7.6	Tabellenvorlagen	177
8	T-Test für unabhängige Stichproben	178
8.1	T-Test anfordern	178
8.2	Interpretation	179
8.3	Prüfung der Voraussetzungen	179
8.4	Empirische Effektstärke	181
8.5	Graphische Veranschaulichung	182
9	Streudiagramme	183
9.1	Streudiagramm anfordern	184
9.1.1	Diagrammerstellung	184
9.1.2	Dialogbox Einfaches Streudiagramm	187
9.1.3	Grafiktafel-Vorlagenauswahl	188
9.2	Streudiagramm per Diagramm-Editor modifizieren	190
9.2.1	Eigenschaftsfenster	191
9.2.2	Markieren von gruppierten Objekten	191
9.2.3	Menüs und Symbolleisten	193
9.2.4	Beschriftungen	195
9.3	Diagramme verwenden	196
9.4	Übung	197
10	Fälle auswählen	199
10.1	Auswahl über eine Bedingung	199
10.2	Bericht anfordern	201
11	Analyse von Kreuztabellen	203
11.1	Untersuchungsplanung	203
11.2	Beschreibung der bivariaten Häufigkeitsverteilung	206
11.3	Die Unabhängigkeits- bzw. Homogenitätshypothese	212
11.4	Testverfahren	213
11.4.1	Asymptotische χ^2 - Tests	213
11.4.2	Schätzung der Effektstärke	217
11.4.3	Einzelvergleiche der Spaltenanteile	218
11.4.3	Exakte Tests	219
11.4.4	Besonderheiten bei (2×2) - Tabellen	222
11.4.4.1	Ein klarer Fall für den exakten Test von Fisher	222
11.4.4.2	Einseitige Hypothesen	222
11.4.4.3	Kontinuitätskorrektur nach Yates	223
12	Fälle gewichten	224
12.1	Beispiel	224
12.2	Übung	225

13	Auswertung von Mehrfachwahlfragen	226
13.1	Mehrfachantworten-Sets definieren	226
13.2	Häufigkeitstabellen für Mehrfachantworten-Sets	228
13.3	Kreuztabellen für Mehrfachantworten-Sets	232
13.4	Ein sparsames Set kategorialer Variablen expandieren	233
14	Datendateien im Textformat einlesen	236
14.1	Import von positionierten Textdaten (feste Breite)	236
14.2	Import von separierten Daten Textdaten	243
14.3	Überprüfung der revidierten differentialpsychologischen Hypothese	245
15	Einstellungen modifizieren	247
15.1	Allgemein	247
15.2	Beschriftung der Ausgabe	248
15.3	Datei-Speicherstellen	249
16	Anhang	250
16.1	Weitere Hinweise zur SPSS-Kommandosprache	250
16.1.1	Hilfsmittel für das Arbeiten mit der SPSS-Kommandosprache	250
16.1.2	Interpretation von Syntaxdiagrammen	252
16.1.3	Aufbau von SPSS-Programmen	252
16.1.4	Aufbau eines einzelnen SPSS-Kommandos	254
16.1.5	Regeln für Variablenlisten	255
16.1.5.1	Abkürzende Spezifikation einer Serie von Variablen	255
16.1.5.2	Der Platzhalter varlist	255
	Literaturverzeichnis	256

1 Von der Theorie zu den SPSS-Variablen

1.1 Statistik und EDV als Hilfsmittel der Forschung

Erfahrungswissenschaften bemühen sich um allgemeingültige Aussagen beschreibender, erklärender oder prognostizierender Art. In vielen Anwendungsbereichen sind dabei *deterministische* Gesetze (z.B. Ohmsches Gesetz der Elektrik, Hebelgesetz der Mechanik) kaum zu finden, und man benötigt eine Technologie zur Untersuchung **probabilistischer Gesetze**.

Beispiel: Welchen Effekt hat das Rauchen auf die Entstehung von Lungenkrebs?

1.1.1 Kluge Entscheidungen trotz Unsicherheit

Wie wir wissen, hat das Rauchen auch bei gleicher Dosierung der Schadstoffe keinesfalls für alle Personen dieselben negativen Folgen. Die Frage nach dem Effekt des Rauchens auf die Entstehung von Lungenkrebs ist anhand weniger Einzelbeobachtungen (z.B. der steinalte 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.

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

Zur Untersuchung der Raucherproblematik wird man vielleicht 400 im Idealfall zufällig ausgewählte Erwachsene (= **Beobachtungseinheiten**, **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 Methoden

Mit statistischen Forschungsmethoden lassen sich u.a. die folgenden Fragestellungen bearbeiten:

1.1.1.1 Parameterschätzung

Im Beispiel interessieren u.a. zwei Wahrscheinlichkeiten:

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

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; 0,400].¹

Für die 300 Nichtraucher resultiert die Punktschätzung 0,10 mit dem Vertrauensintervall [0,068; 0,140], das aufgrund der größeren Stichprobe kleiner (präziser) ausfällt.

Bei einem dichotomen Merkmal wie Lungenkrebs 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 schätzt man Verteilungsmomente, 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** zu schätzen, z.B. Regressionskoeffizienten (siehe unten).

1.1.1.2 Hypothesenprüfung

Im Beispiel ist die folgende Frage zu klären:

Ist bei Rauchern das Lungenkrebsrisiko größer 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* größer als bei Nichtrauchern.

- **Alternativhypothese (H_1)**

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

Im Beispiel: Das Lungenkrebsrisiko ist bei Rauchern erhöht.

Bei der Konstruktion eines statistischen Tests zur Entscheidung zwischen den beiden Hypothesen sorgt die oben behauptete Weißheit der statistischen Methodologie dafür, ...

- dass eine wahre Nullhypothese nur mit einer bestimmten, zuvor akzeptierten Irrtumswahrscheinlichkeit erster Art (α -Fehlerrisiko, meist 0,05) verworfen wird,
- dass bei gültiger Alternativhypothese die falsche Nullhypothese mit möglichst großer Wahrscheinlichkeit verworfen wird (hohe Teststärke, kleine Irrtumswahrscheinlichkeit zweiter Art, geringes β -Fehlerrisiko).

Auch zur Klärung der Frage, welche Stichprobengröße erforderlich ist, um einen Populationseffekt bestimmter Größe (z.B. Risiko(Raucher) = 0,3; 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.


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

1.1.1.3 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 Kriterium Y , einen Regressor X und ein Residuum ε enthält:

$$Y = \beta_0 + \beta_1 X + \varepsilon, \text{Var}(\varepsilon) = \sigma^2$$

Als Modellparameter treten der Ordinatenabschnitt β_0 und der Steigungskoeffizient β_1 , die gemeinsam eine Regressionsgerade definieren, sowie die Varianz σ^2 des Residuums auf. 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 gültigen Modell ausgehen dürfen.² Unter dieser Voraussetzung sind die Punktschätzung, das Konfidenzintervall und der Signifikanztest zum Steigungsparameter β_1 von zentralem Interesse. Bei einem gerichteten (einseitigen) Signifikanztest stehen z.B. die beiden folgenden Hypothesen zur Konkurrenz:

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 beide Geschlechtsgruppen im Mittel unterschiedlich robust gebaut sind, wächst das Gewicht unterschiedlich schnell mit der Größe. Um diese Verhältnisse korrekt zu modellieren, ist ein relativ anspruchsvolles Modell mit Interaktionsterm erforderlich (siehe z.B. Baltes-Götz 2009a), das zum aktuellen Abschnitt nicht gut passen würde.


² Eine Prüfung der Residuen auf Normalverteilung ersparen wir uns an dieser Stelle (vgl. Abschnitt 7.4.1).

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

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

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \varepsilon, \text{Var}(\varepsilon) = \sigma^2$$

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 zahlreiche Parameterschätzungen und Hypothesentests beteiligt. Das folgende Pfadmodell zu den Bedingungen der beruflichen Ambitionen von Kindern (Kerchoff 1974) enthält ein rein-endogenes Kriterium (berufliche Ambitionen des Kindes), einen *Mediator* (Schulleistungen des Kindes) sowie drei exogene Regressoren (Intelligenz des Kindes, Bildung des Vaters, Beruf des Vaters):¹



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 populistischen Formulierung kommt die reale Gefahr zum Ausdruck, dass Menschen bei der Anwendung statistischer Methoden auf komplexe, durch Unsicherheit geprägte Sachverhalte aufgrund einer Täuschungsabsicht 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

¹ In diesem Beispiel ist die völlige Fixierung auf väterliche Karrieremerkmale wohl der im letzten Jahrtausend noch mangelhaften Emanzipation anzulasten.

Merkmale erheben, z.B. Alter, Geschlecht, 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 graphische Darstellungsmöglichkeiten
- eine umfangreiche Unterstützung bei der Datenverwaltung und -aufbereitung
- diverse Verfahren zur Kooperation mit anderen Programmen (z.B. Zwischenablage, Programmierschnittstellen, Datenbankzugriff)

Weil SPSS auf allen wichtigen Plattformen 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 1995; Eid et al. 2010; 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 und ausführliche 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 Datenbanken und/oder aus eigener Forschungstätigkeit stammen können.

1.2.2 Datenquellen

Besteht zur Klärung einer empirischen Forschungsfrage die Möglichkeit zur **Sekundäranalyse** von vorhandenen Daten, soll diese Chance aus wirtschaftlichen Gründen genutzt werden. Bekannte Beispiele für öffentlich zugängliche Datenbestände sind:

- **Allgemeine Bevölkerungsumfrage der Sozialwissenschaften (ALLBUS)**
Das GESIS - Institut für die Sozialwissenschaften befragt seit 1980 alle zwei Jahre eine repräsentative Stichprobe der deutschen Bevölkerung.¹
- **Sozio-oekonomisches Panel (SOEP)**
Das Deutsche Institut für Wirtschaftsforschung (DIW) führt seit 1984 eine jährliche sozioökonomische 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 (*GE*meinsames *NE*ues *St*atistisches *IN*formations-System) aggregierte Daten aus diversen Bereichen der amtlichen deutschen Statistik (z.B. volkswirtschaftliche Indizes, Bildung).³
- **General Social Survey (GSS)**
Seit 1972 wird regelmäßig eine Stichprobe der US-Amerikanischen Bevölkerung zu einer breiten Themenpalette befragt.⁴

Zahlreiche weitere Datenquellen werden in Baur & Fromm (2011, S. 61ff) beschrieben.

1.2.3 Untersuchungsplanung

Ist eine eigene Studie erforderlich, sind bei der Untersuchungsplanung zahlreiche Aufgaben zu lösen.

1.2.3.1 Festlegung der Beobachtungseinheit(en) und der zu untersuchenden Merkmale

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

Gelegentlich sind **hierarchisch geschachtelte Untersuchungseinheiten** auf mehreren Ebenen zu betrachten (siehe z.B. Raudenbush & Bryk 2002). So hat man es etwa bei einer Studie zur Arbeitszufriedenheit und Produktivität von Arbeitnehmern aus verschiedenen Firmen in Abhängigkeit von Person- und Organisationsmerkmalen mit Beobachtungseinheiten auf zwei Ebenen zu tun:

- Firmen
- Arbeitnehmer

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 untersten Ebene (Im Beispiel: auf der Ebene der Arbeitnehmer) naturgemäß anzutreffende Abhängigkeit der *Beobachtungen* muss in speziellen Modellen berücksichtigt werden, um gültige Vertrauensintervalle und Hypothesentests zu erhalten. Das Demonstrationsprojekt in unserm Kurs kommt mit einer konventionellen, flachen Datenstruktur aus, und die Behandlung der speziellen Optionen und Probleme der Mehrebenenanalyse bleibt einem speziellen ZIMK-Kurs vorbehalten (siehe Baltes-Götz 2013b).

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 <http://www3.norc.umd.edu/GSS+Website/>
http://en.wikipedia.org/wiki/General_Social_Survey

1.2.3.2 Entscheidung für ein Untersuchungsdesign

Sie können z.B. einen (quasi-)experimentellen Untersuchungsplan entwerfen oder eine Beobachtungsstudie wählen, die quer- oder längsschnittlich angelegt sein kann. Auf dem Weg zu der im Regelfall anzustrebenden kausalen Analyse gilt das Experiment nach wie vor als Königsweg (siehe z.B. Antonakis, et al. 2010; Eid et al. 2010, S. 56ff), doch muss man speziell in den Wirtschafts- und Sozialwissenschaften oft aus ethischen und/oder praktischen Erwägungen mit Beobachtungsdaten arbeiten.

Bei 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 allen Bedingungen 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 oft Übertragungen zwischen den Bedingungen zu befürchten (z.B. durch Lerneffekte), die manchmal durch eine Variation der Bedingungsreihenfolge neutralisiert werden können. Bei einem Gruppierungsfaktor wird jeder Fall nur unter *einer* Bedingung beobachtet, wobei in der Regel eine Zufallszuordnung stattfindet. Die interindividuellen Unterschiede erschweren als Fehlervarianzquelle den Nachweis eines Effekts.

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

1.2.3.3 Operationalisierung der zu untersuchenden Merkmale

Zur Operationalisierung von theoretischen Begriffen (z.B. sozioökonomischer Status, Optimismus) sind möglichst valide und reliable 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 (z.B. durch vergrößerte Messung entstandene) Daten. Vor allem kann man mit SPSS zu einer metrischen Variablen nach Belieben klassifizierte Varianten erzeugen, wenn dies für spezielle Analysen wünschenswert erscheint (z.B. für eine Häufigkeitsanalyse). Eine Ausnahme von der Empfehlung zur Erfassung 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 spielen auch die verfügbaren technischen Hilfsmittel für die Datenerhebung und -erfassung eine Rolle. Mit Hilfe der Computer-Technik ist eine interaktive, individualisierte und dabei auch noch ökonomische Datenerhebung möglich. Bei der zeitgenauen Steuerung experimenteller Abläufe kommen spezielle Rechner im Forschungslabor zum Einsatz. Für eine kontinuierliche, alltagsbegleitende Datenerfassung können oft Rechner im Taschenformat genutzt werden. Befragungen werden mittlerweile routinemäßig via Internet realisiert, wenn die zu untersuchende Population auf diesem Weg erreichbar ist.

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, schrumpft also. Immerhin ist man berechtigt, nach einem signifikanten Ergebnis beim zweiseitigen Test doch noch eine Richtungsangabe 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 11). 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. Zu jedem Test ist das Fehlriskiko erster Art (α -Fehler) festzulegen, wobei z.B. die 5%-Konvention übernommen werden kann.

1.2.3.6 Stichprobenrekrutierung

Es ist zu überlegen, wie eine repräsentative und zur Durchführung der geplanten Auswertungsverfahren hinreichend große **Stichprobe** rekrutiert werden kann. Bei ausgeprägt konfirmatorisch angelegten Studien ist bei der Stichprobenumfangsplanung insbesondere das **Fehlerrisiko zweiter Art** (der β -Fehler) zu berücksichtigen.

1.2.3.7 Datendeklaration und Kodierplan

Wer ganz sicher gehen will, dass die bei einer 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 oder für eine Datenerfassung per Scanner geschieht die Datendeklaration gegenüber

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

der jeweils 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. Häufig werden die 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. Anfänger(innen) werden bei der Arbeit mit einem Computer-Programm, das die vorwiegend forschungslogisch und kaum durch EDV-Restriktionen diktierte Datenstruktur explizit einfordert, konzeptionelle Probleme eventuell 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 Datendateien (gegenüber einem größeren Nutzerkreis) dienen.

1.2.4 Durchführung der Studie inklusive Datenerhebung

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

1.2.5 Datenerfassung und -prüfung

Nach einer Datenerhebung mit einem in Papierform vorgelegten Fragebogen stehen als Nächstes folgende Arbeiten an:

- **Datenerfassung**

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.

Bei schriftlichen Befragungen großer Stichproben kann eine Anlage zum automatischen Einscannen und Interpretieren von Untersuchungsdokumenten rentabel eingesetzt werden. Voraussetzung ist dann u.a. die Beachtung einiger Regeln beim Entwurf des Fragebogens.

- **Überprüfung auf Erfassungsfehler**

Je fehleranfälliger die gewählte Erfassungsmethode war, desto mehr Aufwand ist bei der Datenprüfung angebracht.

Bei einer Online-Datenerhebung entfällt die Datenerfassung. Im Abschnitt 3.1.1 folgen weitere Informationen zu den Techniken der automatischen Datenerhebung- bzw. -erfassung.

1.2.6 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 Mittelwertsbildung). Solche Transformationen nehmen

bei vielen Projekten einen erheblichen Umfang an, wobei sowohl akribische Fleißarbeit als auch kreative Begriffsbildung gefragt sind.

1.2.7 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 Untersuchungsplanung für das Demonstrationsprojekt

Um die im Rahmen einer empirischen Untersuchung mit SPSS zu erledigenden Arbeiten in einem realistischen Kontext üben zu können, wird im Verlauf des Kurses eine kleine psychologische Fragebogenstudie durchgeführt.¹ Dabei werden Sie alle Phasen der empirischen Forschung von der ersten Idee bis zur statistischen Hypothesenprüfung mit SPSS 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 werden 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 Studie 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 Beobachtungseinheiten, Merkmale, Design und Operationalisierung

Hinsichtlich des Untersuchungsdesigns haben wir uns aufgrund praktischer Erwägungen bereits auf eine **querschnittlich angelegte Fragebogenstudie** mit den Kursteilnehmern als **Beobach-**

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.

tungseinheiten festgelegt. Zentrales **Merkmal** ist der Ärger über ein negatives Ereignis bei An- bzw. Abwesenheit einer kontrafaktischen (also positiven) Ereignisalternative.

Das Interesse am Ärger aufgrund bestimmter 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) 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 (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 des 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 Abschnitt 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 Alternative im Mittel <i>nicht</i> mehr Ärger als in der Rolle des Geschädigten mit „weit entfernt“ 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 Verteilungsformen 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:

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

1.3.2.3 Entscheidungsverfahren

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

In unserem Fall beziehen sich die Voraussetzungen des t-Tests für verbundene Stichproben auf die *Differenz* der beiden Ärgerausprägungen:

- Für die Ärgerdifferenz wird eine Messung auf Intervallniveau benötigt.
- Die Ärgerdifferenz muss in der Population normalverteilt sein (siehe Abschnitt 7.1).

Sind diese Bedingungen *nicht* erfüllt, ist der t-Test für verbundene Stichproben unzulässig und besitzt außerdem in der Regel *keine* gute Teststärke. Während kaum Zweifel am Intervallniveau

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

der Messung bestehen (und auch kein diesbezüglicher Test möglich ist), werden wir die Normalverteilungsannahme 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 $\alpha = 5\%$ 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. 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

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. 2010, S. 63). Dies ist bei der KFA-Hypothese kaum zu befürchten.

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 Beobachtung 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.

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

Die Firma IBM SPSS unterstützt solche Berechnungen im Zusatzprogramm **SamplePower**, das uns auf den Pool-PCs der Universität Trier leider nicht zur Verfügung steht. Stattdessen verwenden wir das exzellente Power-Analyse-Programm **G*Power 3.1** (Faul et al. 2007, 2009), das für MacOS 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 folgende Programmgruppe starten

Start > Alle Programme > Wissenschaftliche Programme > 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 Erfahrungen festlegen zu können:



Unsere KFA-Hypothese handelt vom *Ärgerzuwachs* aufgrund der kontrafaktischen Alternative 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.

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

$$d_z := \frac{\mu_z}{\sigma_z}$$

Darin sind:

- μ_z Mittelwert der Differenz (hier: *Ärgerzuwachs*) in der Population
- σ_z Standardabweichung der Differenz in der Population

Indem man den Abstand des Lageparameters μ_z von der neutralen Null 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) 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 Effektstärke begründen, so dass kein Rückgriff auf fragwürdige Konventionen erforderlich ist. Beim Ärgerzuwachs wird ein Erwartungswert (Hauptparameter der KFA-Hypothese) 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 eine Stichprobe mit 13 Fällen erforderlich ist. 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 Eid et al. 2010, 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).



Man kann das Protokoll in eine RTF-Datei 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 unten). 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:

$$Y = \beta_0 + \beta_1 X + \varepsilon, \text{Var}(\varepsilon) = \sigma^2$$

Als Modellparameter treten der Ordinatenabschnitt β_0 und der Steigungskoeffizient β_1 , die gemeinsam eine Regressionsgerade definieren, 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 (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. 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 mit einem α -Fehler – Risiko von 5% 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 5% 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.

Wir nehmen einen Determinationskoeffizienten von 0,09 (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**.

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 differenti-alpsychologischen 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 von Effektstärken für lineare Regressionsmodelle in den Verhaltens- und Sozialwissenschaften finden sich bei Cohen (1988, S. 412ff) folgende Orientierungswerte:

Effektstärke in der Population	Partielles R^2	f^2
klein	0,02	0,02
mittel	0,13	0,15
groß	0,26	0,35

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 20 Fälle erforderlich, so dass für die differentialpsychologische Hypothese auch in der relativ kleinen Kursstichprobe noch Anlass zur Hoffnung besteht.

Bei der Stichprobenumfangsplanung ist es in der Regel 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 Demographische Merkmale

Auf die Erfassung demographischer Merkmale (siehe Fragebogenteil 4) kann man in keiner Studie mit Personen als Beobachtungseinheiten verzichten, auch wenn sich keine expliziten Hypothesen darauf beziehen. Man benötigt sie auf jeden Fall zur Beschreibung der Stichprobe, damit sich später die Leser(innen) von Berichten ein Urteil über die Interpretier- bzw. Generalisierbarkeit der Ergebnisse bilden können. Wir werden darüber hinaus einige demographische 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 demographische Fragen nicht am Anfang einer Umfrage stehen:

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

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

Statt nach dem Alter wird im Beispielfragebogen nach dem Geburtsjahr gefragt, weil manche Auskunftspersonen diese Information leichter und genauer liefern können.

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:

- Größe und Gewicht (siehe Fragebogenteil 4)
Mit diesen Merkmalen lassen sich manche statistische Verfahren gut demonstrieren. Außerdem sorgen sie für das Auftreten gebrochener Zahlen in unseren Daten.
- Motive zur Kursteilnahme (siehe Fragebogenteil 3)
Mit diesen Merkmalen lässt sich üben, wie die aus Mehrfachwahlfragen und offenen Fragen resultierenden Informationen deklariert, erfasst und analysiert werden können.

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	unentschieden	stimmt	stimmt genau
1. Auch in unsicheren Zeiten rechne ich im Allgemeinen damit, dass sich alles zum Besten wendet.	--	-	0	+	++
2. Ich kann mich leicht entspannen.	--	-	0	+	++
3. Wenn etwas schief gehen kann, dann passiert es mir auch.	--	-	0	+	++
4. Bei allem sehe ich stets die negative Seite.	--	-	0	+	++
5. Ich blicke kaum einmal mit Zuversicht in die Zukunft.	--	-	0	+	++
6. Ich bin gern mit Freunden zusammen.	--	-	0	+	++
7. Ich muss mich immer mit etwas beschäftigen.	--	-	0	+	++
8. Ich habe stets die Hoffnung, dass die Dinge in meinem Sinne gehen.	--	-	0	+	++
9. Die Dinge laufen immer so, wie ich es mir wünsche.	--	-	0	+	++
10. Ich bin nicht leicht aus der Ruhe zu bringen.	--	-	0	+	++
11. Ich glaube an den sprichwörtlichen "Silberstreifen am Horizont".	--	-	0	+	++
12. Dass mir einmal etwas Gutes widerfährt, damit rechne ich kaum.	--	-	0	+	++

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 ☐
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 *automatischen* Erhebung bzw. Erfassung (Online-Formular, Daten-Scanner) 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 den automatischen Methoden teilweise bei der Datendeklaration gegenüber der Online-Befragungs - bzw. Daten-Scanner - Software geregelt und teilweise von der 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- oder Scanner-Lösung 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. **Beobachtungseinheiten** 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-Dateneditor-fenster** wird das Verständnis der anschließenden, wieder eher allgemein-methodologisch geprägten, Ausführungen sicher 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 SPSS-Kurs. Diese Datenmatrix ist durch Erfassung der per Fragebogen gesammelten Informationen unter strikter Anwendung des Kodierplans entstanden:

	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	2	3	2	3	4	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 Kodierungsbe-mühungen 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 Fra-gebogen 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 Variab-len 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). 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-Datentabelle sechs Variablen, um die Antworten aufzunehmen, die wir z.B. durch die Zahlen Eins (für *trifft zu*) und Null (für *trifft nicht zu*) kodieren können.

Beim Umgang mit einer solchen 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.

1.4.2.3.1 Vollständige Sets aus dichotomen Variablen

In unserem Beispiel 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 13 ein so genanntes **Mehrfachantworten-Set** 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 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-Datentabelle 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 Mehrfachantworten-Set zu definieren, diesmal bestehend aus den beiden Variablen MOTIVA und MOTIVB. Bei manchen Auswertungen ist es aber doch erforderlich, über Transformationsanweisungen aus dem sparsamen kategorialen Set das vollständige dichotome Set (mit *einer* Variablen pro Merkmal) herzustellen (siehe Abschnitt 13.4).

1.4.2.4 Offene Fragen

Offene Fragen lösen vielfältige und oft schwer strukturierbare Antworten aus, und es bleibt dann offen, ob und wie die Antworten in SPSS-Variablen übersetzt werden sollen. Der übliche Weg zur Systematisierung und Erfassung der Antworten 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 auf eine Mehrfachwahlfrage behandeln.

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:

Regressionsanalyse
Kreuztabellenanalyse
Faktorenanalyse
Diskriminanzanalyse

Bei der Umsetzung in SPSS-Variablen wird man bei einer relativ kurzen Kategorienliste ein vollständiges Set mit dichotomen Variablen verwenden, ansonsten ein sparsames Set aus 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:

REG für die Regressionsanalyse
KT für die Kreuztabellenanalyse
FAKT für die Faktorenanalyse
DA für die Diskriminanzanalyse

Bei der Variablen REG ist bei der sich anbietenden (0/1)-Kodierung eine 1 einzutragen, wenn ein Fall auf die offene Frage hin die 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 Regressionsanalyse zu interpretieren ist.

- 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

Für jedes erhobene Merkmal muss festgelegt werden, wie die einzelnen Merkmalsausprägungen 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.

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

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

² <http://www.maxqda.de/>

- **Zeichenkettenvariablen (synonym: alphanumerische Variablen, String-Variablen)**
 Werte: Folgen von Zeichen (Buchstaben, Ziffern, Sonderzeichen) mit der maximalen Länge:
 bis zur SPSS-Version 12: 255 Zeichen
 seit der SPSS-Version 13: 32767 Bytes
 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: Geburtsdatum

Anwendungsfälle für Datumsvariablen dürften in der Regel klar erkennbar sein. Ansonsten müssen Sie sich nur zwischen der numerischen und der alphanumerischen Kodierung entscheiden. Bei Merkmalen mit **mindestens ordinalem Skalenniveau** ist offensichtlich nur die numerische Kodierung sinnvoll. Bei Merkmalen mit **Nominalskalenniveau** hat man hingegen 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 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).

1.4.3.2 Das Problem fehlender Werte

Trotz aller Sorgfalt sind in fast jedem Forschungsprojekt bei manchen Fällen einige Merkmalsausprägungen unbekannt, z.B. wegen technischer Probleme oder wegen nachlässig ausgefüllter Fragebögen. Bei der Kodierungsplanung muss für alle betroffenen Variablen festgelegt werden, welche Ersatzwerte an Stelle fehlender oder ungültiger Werte in die zugehörigen Zellen der Datenmatrix eingetragen werden sollen. Diese Ersatzwerte bezeichnet man häufig als *MD-Indikatoren*, wobei *MD* für *Missing Data* steht. Wir beschränken uns bei der anschließenden Behandlung des Themas auf 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 verweigerten 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.

Wichtig: Für jede betroffene Variable müssen dem SPSS-System alle benutzerdefinierten MD-Indikatoren bekannt gemacht werden (siehe Abschnitt 3.2.2).

Die für so genannte **Residualkategorien** (z.B. „Weiß nicht“, „Keine Antwort“) 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 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 Kompletieren 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.

1.4.3.2.4 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(innen) 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.	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 6).


1.4.3.4 SPSS-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 5 und 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 verschmähten 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. Man kann z.B. die freie Statistik-Programmiersprache **R** gut in SPSS integrieren und dabei in R-Anweisungen auf SPSS-Variablen zugreifen, solange deren Namen keine Umlaute enthalten (siehe Baltes-Götz 2013a). 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, jedoch verwendet SPSS bei *Ausgaben* die Schreibweise aus der Variablendeklaration. Ist zu einer Variablen allerdings zusätzlich ein Variablenlabel (siehe unten) definiert, erscheint dieses in der Ausgabe an Stelle des Namens. Wir schreiben in SPSS die Variablennamen aus Bequemlichkeitsgründen meist in Kleinbuchstaben. In Manuskript erscheinen sie zur Hervorhebung in Großbuchstaben.

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, also z.B. FNR, GESCHL und GEBJ für *Fallnummer*, *Geschlecht* und *Geburtsjahr* an Stelle informationsarmer Bezeichnungen wie V1, V2, V3, ...
- Die eben genannte Regel muss 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 der Kodierplan 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 = 0 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 MD-Indikator: 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 erfreulich 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 eventuell 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). Hier 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

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	unentschieden	stimmt	stimmt genau
1. Auch in unsicheren Zeiten rechne ich im Allgemeinen damit, dass sich alles zum Besten wendet.	--	-	o	+	++
2. Ich kann mich leicht entspannen.	--	+	o	+	++
3. Wenn etwas schief gehen kann, dann passiert es mir auch.	--	+	o	+	++
4. Bei allem sehe ich stets die negative Seite.	+	-	o	+	++
5. Ich blicke kaum einmal mit Zuversicht in die Zukunft.	--	+	o	+	++
6. Ich bin gern mit Freunden zusammen.	--	-	o	+	+
7. Ich muss mich immer mit etwas beschäftigen.	--	-	+	+	++
8. Ich habe stets die Hoffnung, dass die Dinge in meinem Sinne gehen.	--	-	o	+	++
9. Die Dinge laufen immer so, wie ich es mir wünsche.	--	-	o	+	++
10. Ich bin nicht leicht aus der Ruhe zu bringen.	--	-	+	+	++
11. Ich glaube an den sprichwörtlichen "Silberstreifen am Horizont".	--	-	o	+	++
12. Dass mir einmal etwas Gutes widerfährt, damit rechne ich kaum.	--	+	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 (HWT-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. Bei der in Abschnitt 3.1.1.2 vorzustellenden Daten-Scanner-Lösung *TeleForm* kann man die Fallnummern per Seriendruck automatisch anbringen lassen.

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, und in den Abschnitten 2.2 bis 2.5 werden elementare Eigenschaften des Programms dargestellt.

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 > Wissenschaftliche Programme

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

Im Oktober 2013 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 die Software 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 (unter Windows optional inklusive Zu-

satzprogramme) auf einem Rechner mit permanentem Internetzugang (an der Uni oder im Privatbereich) zur kostenlosen Nutzung der ZIMK-Lizenzserver installieren.

Unterstützte Programme:

- **SPSS Statistics**
- **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.


Enthaltene Programme:

- **SPSS Statistics**
- **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 21 über das Desktop-Symbol




oder über das Startmenü:

Start > Alle Programme > Wissenschaftliche Programme > SPSS > IBM SPSS Statistics 21

Auf einem PC unter Windows mit lokaler SPSS-Installation können Sie das Programm in der Regel so starten:

Start > Alle Programme > IBM SPSS Statistics > IBM SPSS Statistics 21


Nach dem Start erscheint der folgende Assistent:



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 **SPSS Statistics Viewer** genannt, z.B.:



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

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 Menüleiste 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.
- **Diagramme**
An dieser Stelle bietet SPSS vielfältige Möglichkeiten zur graphischen 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 Menüleisten.

2.3 Das Hilfesystem

Bei der Arbeit mit SPSS können Sie stets auf ein mächtiges Hilfesystem zurückgreifen, dessen wichtigste Möglichkeiten nun 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.:




Index Suchen

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 Fallstudien

Nach **Hilfe > Fallstudien** startet ein Angebot, das mit der interaktiven Technik des Lernprogramms arbeitet, aber den Schwerpunkt auf statistische Analysen legt.



Viele Auswertungsverfahren werden über ein komplettes Anwendungsbeispiel und Informationen zu folgenden Themen erschlossen:

- Einsatzmöglichkeiten
- Voraussetzungen der Analyse
- Interpretation der Ergebnisse
- Verwandte Verfahren
- Literaturangaben

2.3.6 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 eBooks im PDF-Format 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. 2.500 Seiten. Dieses PDF-Dokument ist auch im Hilfesystem verfügbar (**Hilfe > Befehlssyntax-Referenz**).

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 sicher unvollständig ist:

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

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

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

Field (2009). *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 (2007). *Using multivariate statistics*

Die vollständigen bibliographischen 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, besonders zu erwähnen sind:

- **Die IBM-Webseite zu SPSS**
<http://www-01.ibm.com/software/analytics/spss/>
- **Die Usenet-Diskussionsgruppe comp.soft-sys.stat.spss**
<http://spssx-discussion.1045642.n5.nabble.com/>
Hier werden technische und statistische Themen lebhaft diskutiert, wobei auch SPSS-Mitarbeiter zu wichtigen Fragen kompetent Stellung nehmen.

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 Automatisierte Verfahren

Zunächst geht es um zwei Optionen zur Rationalisierung der Datenerhebung bzw. -erfassung.

3.1.1.1 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(innen) 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 oft 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 per Paper/Pencil 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 sorgfältig 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**

Als Ursachen sind u.a. zu nennen:

- Die unterschiedliche Netzaffinität verschiedener Gesellschaftssegmente. Ältere Personen sind im Internet seltener anzutreffen als jüngere, Frauen seltener als Männer und niedrige soziale Schichten seltener als gehobene (Jacob et al 2013, S. 112).
- Die immer noch lückenhafte Versorgung mit einem (schnellen) Internetzugang. Nach einer Pressemitteilung des statistischen Bundesamts verfügten 2011 nur 77% der deutschen Haushalte über einen Internetzugang, wobei immerhin 93% der Anschlüsse mit Breitbandtechnik ausgestattet war.¹

Durch Gewichtungs- und Modellierungstechniken 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)

- **Kompetenzbedarf und Fehlerrisiko**

Zur Konfiguration einer Online-Umfrage sind Software-Kenntnisse erforderlich, und es sind Fehler mit erheblichen Auswirkungen möglich.

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.

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

Statistisches Praktikum mit SPSS

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°
Herr Meier wären?	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐
Herrn Schulze wären?	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐

Betrachten Sie bitte die Antwortskala als "Ärgerthermometer".

[Weiter](#)

Wer an der Universität Trier eine Online-Datenerhebung mit Unipark durchführen möchte, erhält die erforderliche Zugangsberechtigung und Unterstützung in der ZIMK-Benutzerberatung (vermittelt über die ZIMK - Service-Punkte, siehe Abschnitt 2.4.3).

¹ https://www.destatis.de/DE/PresseService/Presse/Pressemitteilungen/2011/12/PD11_474_63931.html

3.1.1.2 *Automatisches Einscannen von schriftlichen Untersuchungsdokumenten*

Auch bei einer schriftlichen Befragung im konventionellen Stil lässt sich das manuelle Erfassen der Daten vermeiden. Diese lästige und fehleranfällige Arbeit kann man einer EDV-Anlage zum automatischen Einscannen und Interpretieren der schriftlichen Untersuchungsdokumente übertragen. Allerdings muss die EDV-Anlage erst mit einigem Aufwand in ihre Arbeit eingewiesen werden, so dass bei kleineren Projekten kaum ein Rationalisierungsgewinn zu erzielen ist.

In der Regel macht ein Gespann aus Scanner und Software bei der Datenerfassung weniger Fehler als ein Mensch, z.B. weil Ermüdung und Konzentrationsmängel als Fehlerursachen ausscheiden. Andererseits hat die Technik bei der Erkennung von undeutlichen oder fehlplazierten Markierungen von Antwort-Kästchen mehr Probleme als ein Mensch. Über Probanden, die trotz entsprechender Instruktion ihren Fragebogen nachlässig ausfüllen oder ein kontrastarmes Schreibgerät verwenden, bleibt der Faktor Mensch bei Scanner-Lösungen im Spiel.

An der Universität Trier steht für die Datenerfassung per Scanner im Pool-Raum E044 das Programm **TeleForm 10.5.2** mit der erforderlichen Hardware (Scanner mit automatischem Einzelblatteinzug) zur Verfügung. Das Programm kann folgende Informationen erfassen:

- Markierungen der Optionen zu Einfach- oder Mehrfachwahlfragen (OMR)
- gedruckte Zeichen (OCR)
- Handschrift (ICR)

Es enthält einen Formulargenerator, so dass Fragebogendesign und -deklaration in einem Arbeitsschritt erfolgen.

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 mit Erfassungsmaske, Plausibilitätskontrolle und Filterführung eingesetzt werden (vgl. Abschnitt 3.1.1.1). Diese Lösung hat sogar den Vorteil, dass an den Erfassungsplätzen als Software nur ein Betriebssystem und ein Web-Browser benötigt werden.

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:

- **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

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

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 35). 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 Variablen-


definition 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:



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-Variablennamen wurden schon im Zusammenhang mit dem Kodierplan genannt (siehe Seite 32).
- **Typ**
Die wichtigsten SPSS-Variablentypen sind schon benannt: Numerisch, String und Datum (siehe Seite 27). 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.

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.

- **Spaltenformat**

Bei einer *numerischen* Variablen beeinflusst dieses Attribut lediglich ihre voreingestellte Breite (inkl. Vorzeichen und Dezimaltrennzeichen) bei der Ausgabe in eine Textdatenda- tei (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 *alphanumerischen* Variablen legt das Spaltenformat die maximale Anzahl der gespeicherten Zeichen fest und ist folglich recht bedeutsam. So werden z.B. bei einer nachträglichen Reduktion der Spaltenzahl tatsächlich entsprechend viele Zeichen am rechten Rand gelöscht.

- **Dezimalstellen**

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

- **Variablenlabel**

Hier können optional Variablenlabel mit einer beliebigen Länge vereinbart werden, die in Ergebnistabellen und Diagrammen an Stelle der aus praktischen Erwägungen möglichst kurz gewählten und mit Syntaxrestriktionen belasteten Variablennamen (z.B. Verbot von Leer- und Sonderzeichen) angezeigt werden sollen, z.B.:

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

Allerdings erscheinen die Labels in der Ausgabe mancher SPSS-Prozeduren nicht in vol- ler Länge.

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

- **Wertelabels**

Hier kann man Werteetiketten mit maximal 120 Zeichen definieren, die in Ergebnistabel- len und Graphiken an Stelle der Werte erscheinen. SPSS empfiehlt Wertelabels bei no- minalen und bei ordinalen Variablen. Bei numerisch kodierten nominalskalierten Merk- malen 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), son- dern beeinflusst auch die Berücksichtigung von Kategorien: Soll eine unbesetzte Katego- rie in einem Diagramm erscheinen (z.B. als Balken mit der Höhe Null), muss ein Werte- label vorhanden sein.


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

In der Datenansicht bietet der Dateneditor über den Menübefehl

Ansicht > Wertelabels

bzw. den Symbolschalter  einige Unterstützung für die Etiketten:

- o Sie werden an Stelle der Werte angezeigt.
- o 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.

• Fehlende Werte

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 Mittelwertbildung. Da wir im KFA-Projekt laut Kodierplan ausschließlich System-Missing als MD-Indikator verwenden, müssen wir anschließend keine MD-Deklaration vornehmen (vgl. Abschnitt 1.4.3.5). Daher wird nun die simple Prozedur zum Deklarieren von benutzerdefinierten MD-Indikatoren beschrieben:

- o Markieren Sie bei der betroffenen Variablen die Zelle zum Attribut **Fehlende Werte**.
- o 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.:



• 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 **Skala** (metrisch, Intervall- bzw. Rationalniveau), **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 9.1.1) 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**

Seit der SPSS-Version 18 kann man den Variablen eine Rolle zuweisen, die in einigen Dialogfeldern zur Variablenvorauswahl genutzt wird:

- o **Eingabe**
Die Variable kommt als Regressor (unabhängige Variable) in Frage.
- o **Ziel**
Die Variable kommt als Kriterium (abhängige Variable) in Frage.
- o **Beide**
Die Variable kommt als Regressor (unabhängige Variable) und als Kriterium (abhängige Variable) in Frage.
- o **Keine**
Die Variable erhält keine Rolle.
- o **Partitionieren**
Die Variable dient zur Aufteilung der Stichprobe, z.B. in Modellierungs- und Kreuzvalidierungsfälle.
- o **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 Variablenamen aus darstellungstechnischen Gründen groß geschrieben.

Sobald Sie die Zelle mit dem Variablenamen verlassen (z.B. per Mausklick auf eine andere Zelle oder per Tabulatortaste) wird eine neue Variable mit dem gewünschten Namen in die Ar-

beitsdatei aufgenommen, sofern gegen den Variablenamen 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 einem 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 **Variablenlabel** 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 müssen wir (dank SYSMIS-Option) im KFA-Projekt generell nicht vereinbaren (vgl. Abschnitt 1.4.3.2.2), 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 einem metrischen Messniveau (Intervallniveau) aus und vergeben im SPSS-Dateneditor die zugehörige Attributausprägung **Skala**. 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 (am linken Rand der Tabelle).
- 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

Gehen Sie in der Variablenansicht folgendermaßen vor, um Variablen per Drag & Drop (Ziehen und Ablegen) zu verschieben:

- Markieren Sie die zu verschiebenden Variablen auf Windows-übliche Weise über Mausaktionen im Nummerierungsbereich, ggf. ergänzt durch die **Strg** - und/oder **↑** - Taste. Lassen Sie anschließend die Maustaste wieder los.
- Klicken Sie in der Nummerierungszone 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.

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 am linken Tabellenrand, 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 freien 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:

	Name	Typ	Spaltenformat	Dezimalstellen	Variablenlabel	Wertelabels	Fehlende W...	Spalten	Ausrichtung	Messniveau	Rolle
1	aergm	Numerisch	8	0	Ärger mit KFA	Keine	Keine	4	Rechts	Skala	Eingabe
2	lot1	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
3	lot2	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
4	lot3	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
5	lot4	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
6	lot5	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
7	lot6	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
8	lot7	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
9	lot8	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
10	lot9	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
11	lot10	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
12	lot11	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe
13	lot12	Numerisch	8	0	Keine	Keine	Keine	3	Rechts	Skala	Eingabe

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 am linken Tabellenrand, 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 das Variablenlabel *Geschlecht*. Dabei wird die Empfehlung aus Abschnitt 3.2.2.2 umgesetzt, auch bei nominalskalierten Merkmalen eine numerische Kodierung zu verwenden.

3.2.2.6.1 Wertelabels vereinbaren

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, wel-


ches Geschlecht die Nummer Eins ist. Öffnen Sie daher mit einem Mausklick auf den Erweiterungsschalter  in der markierten **Wertelabels**-Zelle die folgende Dialogbox:



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

- Tragen Sie den **Wert** 1 und das **Wertelabel** *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.

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:



3.2.2.6.2 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.

Wenn Sie an einem Pool-PC an der Universität Trier arbeiten, können Sie die Datei im Ordner **U:\Eigene Dateien\SPSS** speichern, der beim ersten SPSS-Einsatz automatisch angelegt wurde.


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 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 7.7.

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 Optimismus-Testwert, 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 graphischen Analysen darstellt. In fast jedem Projekt sind Variablenmodifikationen und -neuberechnungen in erheblichem Umfang erforderlich.

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

Die zweistufige Projektdatenverwaltung mit Roh- und Fertigdatei 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 > Wertelabels** die Anzeige von Wertelabels 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 Kodiervorschriften möglich, wobei allerdings der Zeitaufwand steigt. Es lohnt sich, die Kodierungsvorschriften im Kopf zu haben. Selbstverständlich ist auch bei aktivierter Labelanzeige die rationelle Werteingabe möglich.

- Tragen Sie die restlichen Werte des ersten Falles ein, jeweils quittiert mit der Tabulatortaste. So sieht der vollständig erfasste erste Fall der Manuskript-Stichprobe im Datenfenster aus (bei abgeschalteter Wertelabels-Anzeige):




- Wenn Sie den Wert der letzten Variablen mit der Tabulatortaste quittieren, setzt SPSS freundlicherweise die Zellenmarkierung gleich in die erste Datenzeile 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 die (von SPSS gesetzte) Zeilennummer des überflüssigen Falles. 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 im Nummerierungsbereich, ggf. ergänzt durch die **Strg** - und/oder  - Taste. Lassen Sie anschließend die Maustaste wieder los.
- Klicken Sie in der Nummerierungszone 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 Umordnungsmaßnahmen 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 bietet sich an, die Definition der Variablen METH1 bis METH3 durch entsprechende Wertelabels 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 graphische Analysen durchgeführt werden können. Wir werden unsere Daten mit Hilfe deskriptiver Auswertungsmethoden auf irreguläre Werte untersuchen. Dabei schlagen wir zwei Fliegen mit einer Klappe, denn eine sorgfältige Verteilungsanalyse aller Variablen gehört ohnehin zu unseren Pflichtaufgaben. Bei vielen Variablen sind wir sogar ausgesprochen neugierig auf die Verteilung (z.B. bei den Variablen AERGO und AERGM).

Eine Beschränkung auf univariate Analysen ist kaum jemals 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 stets 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 3.1.1.1 vorgestellte Online-Umfrage-System, EFS Survey bei einer Einfachwahlfrage mit regulären Werten von 1 bis 5 den Exportwert 0, wenn eine Person zur Seite mit der Frage gelangt ist, aber die Frage nicht beantwortet hat. Anders als der Wert -77, den eine Person erhält, welche die betroffene Seite nie gesehen hat (z.B. wegen Abbruch), wird der Wert 0 in der von EFS Survey gelieferten SPSS-Exportdatei *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) und 2 (für Männer) 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.

Fehlerhafte Werte 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.

Fällt ein Fall durch zahlreiche fehlerhafte und/oder fehlende Werte auf, kommt auch ein Löschen des Falles in Frage. Eine einfach anwendbare Regel lässt sich aber für solche Fälle nicht formulieren.

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. 2012a 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 Firma oder Forschungseinrichtung 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, wenn z.B. Körpergrößeangaben über 230 cm abgewiesen werden. Allerdings fehlen in einer so entstandenen Datei eventuell auch einige Basketballspieler, die empört die Studienteilnahme angebrochen haben, nachdem ihre Körpergröße von z.B. 235 cm abgelehnt wurde. Bei Plausibilitätskontrollen in Online-Erfassungswerkzeugen darf man also nicht zu kleinlich sein.

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 Wertelabels hat zwar manche 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 empfehlenswerten univariaten Verteilungsanalyse geschehen.

Gelegentlich ist eine *bivariate* Verteilungsanalyse erforderlich, um unzulässige, d.h. aus logischen oder überzeugenden 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 graphischen Analyse bzw. Präsentation von Daten zum Einsatz kommt (vgl. Kapitel 9), sollten irreguläre Wertekombinationen einem wachsamem Auge nicht entgehen.

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 verglichen werden.

Eine aufwändige 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:

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

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

Das Stichprobenmittel $\bar{T}$ aus den fehlerfrei erfassten Werten und das Stichprobenmittel $\bar{X}$ aus den fehlerhaft erfassten Werten haben den gemeinsamen Erwartungswert μ .

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 Stichprobenmittel, das als Schätzwert für den Erwartungswert der Population dient, von der Erfassungsfehlervarianz σ_F^2 und von 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:

- Unpräzise Parameterschätzungen
- Reduzierte Power bei Hypothesentests

Wir werden bald die KFA-Wirkung über die Differenzvariable (AERGM – AERGO) beurteilen. Erfassungsfehler können den Stichprobenmittelwert dieser Variablen verfälschen und einen unrealistischen KFA-Effekt vortäuschen. 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, 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 Startassistenten 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

Bei einer für Mausaktionen zugänglichen Datendatei stehen weitere Techniken zum Öffnen zur Verfügung:

- Doppelklick
- Drag & Drop: Ziehen und auf einem 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 14 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.

SPSS übernimmt die eingelesenen Daten in ein neues Datenblatt. In der Regel werden 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. Die meisten der dazu erforderlichen deskriptiven Datenanalysen wären allerdings im Rahmen der routinemäßigen Verteilungsuntersuchungen ohnehin erforderlich.

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


Analysieren > Deskriptive Statistik > 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 Variablenlabels und der dahinter (zwischen eckigen Klammern) folgenden Variablenamen sorgen:



Markieren Sie in der Anwarterliste (links) die Variablen GESCHL und FB, und befördern Sie diese per Mausklick auf den Transportschalter  in die Teilnehmerliste (rechts):




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



Bei einer längeren Liste ist es sehr hilfreich, dass SPSS beim Eintippen einer Variablenbezeichnung das nächste kompatible Listenelement markiert, wobei der Name oder das Variablenlabel (falls vorhanden) anzugeben ist.

Begeben Sie sich anschließend in den Subdialog **Diagramme**, indem Sie einen Mausklick auf den gleichnamigen Schalter setzen. Wählen Sie im Rahmen **Diagrammtyp** die für 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 am 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, der als wesentliches Merkmal unserer Stichprobe berichtet werden muss. Bei potentiell geschlechtsabhängigen Ergebnissen müssen wir besonders vorsichtig interpretieren bzw. generalisieren.

Erste Hinweise zur möglichen Ursache der hohen Frauenquote 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 11.2).

Ein Balkendiagramm zeigt für jede Kategorie ihre absolute oder relative Häufigkeit durch einen Balken entsprechender Höhe. Man kann die Balkenhöhen, also die (relativen) Häufigkeiten der Kategorien, 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 Kategorien einer Variablen sehr gut durch Kreissegmente mit passendem Winkel veranschaulichen, z.B. bei der Variablen FB:




Für eine Kategorie 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 jede Kategorie gut ihren Anteil beurteilen, während der Vergleich mit anderen, nicht direkt benachbarten Kategorien 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 Graphikmöglichkeiten des SPSS-Systems vermittelt. Wir haben eine integrierte Option der Dialogbox zur Häufigkeitsanalyse benutzt und auf eine Nachbearbeitung per Diagramm-Editor verzichtet (siehe Abschnitt 9.2). Die meisten grafischen Darstellungsmöglichkeiten bietet SPSS über das Hauptmenü **Diagramme** an, mit dem wir uns später befassen werden (siehe Kapitel 9).

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 eine 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: **Anmerkungen**) 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 voll ausgenutzt:

- Diagramme werden nur als Bitmap (PNG, JPG) abgelegt, so dass im Zielprogramm nur eine Bitmap (Pixel-Graphik) 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 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 den Mitteln des Zielprogramms editieren lässt.

Befindet sich eine SPSS-Tabelle oder -Graphik 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 mit etwas Spürsinn gelingt:




Wenn Sie beim Einfügen einer Tabelle das Format **Grafik (Windows-Metadatei)** oder das Format **Bild (Erweiterte Metadatei)** wählen, erhalten Sie in der Zielanwendung ein Graphik-Implantat mit dem Original-Design aus dem SPSS-Viewer, wobei das Format **Bild (Erweiterte Metadatei)** eine erheblich bessere Qualität liefert und daher zu bevorzugen ist, wenn beide Formate angeboten werden.

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 treten (zumindest bei entsprechender Messgenauigkeit) sehr viele verschiedene Werte auf, so dass eine Häufigkeitstabelle kaum zur Beschreibung der Verteilung geeignet ist. Stattdessen verwendet man Statistiken (Kennwerte), um die zentrale Tendenz, die Dispersion und die Gestalt einer Verteilung zu charakterisieren. An Stelle des Balkendiagramms, das für jeden Wert einer Variablen einen Balken enthält, verwendet man das **Histogramm**, das


für Intervalle geeigneter Breite die Häufigkeit durch einen Balken darstellt, wobei die Balken in der Regel lückenlos aneinander grenzen.

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**:



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



4.5.1 Maße der zentralen Tendenz

Ein Maß der zentralen Tendenz soll die typische Variablenausprägung angeben. Die SPSS-Prozedur zur Häufigkeitsanalyse kann folgende Statistiken 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.
- **Median**
Sobald die Merkmalsausprägungen nach der Größe geordnet werden können (ab ordinalem Messniveau) kann der als *Median* bezeichnete Wert bestimmt werden, der genau 50% der Fälle links von sich lässt. Alternative Bezeichnungen sind:
 - o 50. Perzentil (P_{50})
 - o 2. Quartil (Q_2)
 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.
- **Mittelwert**
Das arithmetische Mittel ist der beste Schätzer für den Erwartungswert, sofern keine irregulären Daten (Ausreißer) vorliegen.

Einsatzempfehlungen für die Maße der zentralen Tendenz:

- Bei nominalskalierten Merkmalen kommt nur der Modus in Frage.
- Bei ordinalskalierten Merkmalen eignen sich Median und Modus.
- Bei metrischen Merkmalen mit symmetrischer Verteilung ist der Mittelwert als Maß der zentralen Tendenz zu bevorzugen.
- Bei metrischen Merkmalen mit asymmetrischer Verteilung sollte man Mittelwert und Median bestimmen.

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 wenig Information eingeht, ist die Spannweite selten ein gutes Maß für den Grad der Unterschiedlichkeit zwischen den Werten eines Merkmals.

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

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


Sein Vorteil gegenüber Varianz und Standardabweichung besteht in der Unempfindlichkeit gegenüber Ausreißern (extremen, ungewöhnlichen Werten).

1.1.5 Schiefe und Wölbung

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

4.5.2.1 Schiefe

Bei einem symmetrisch verteilten Merkmal hat die Schiefestatistik den Wert Null. 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 7.3) 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

4.5.2.2 Wölbung (Kurtosis)


Die Wölbung (synonym: *Kurtosis*) ist bei normalverteilten Merkmalen gleich Null. Sie wird *positiv (negativ)*, wenn sich im Vergleich zur Normalverteilung *mehr (weniger)* Verteilungsmasse an den Rändern befindet. Mit Hilfe des zugehörigen Standardfehlers können analog zum Vorgehen bei der Schiefe-Statistik (siehe oben) approximativ (bei unendlich großen Stichproben) gültige Tests zur Wölbung in der Population durchgeführt werden.

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

4.5.2.3 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, Standardabweichung, Varianz, Minimum, Maximum, Schiefe, Kurtosis
Zur Auswahl der gewünschten **Statistiken** müssen Sie die zuständige Subdialogbox per Knopfdruck aktivieren:



- 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 Verteilungen von Beobachtungsvariablen, sondern auf die Verteilungen der *Residuen* eines bestimmten statistischen Modells. Nähere Aussagen sind nur im Zusammenhang mit konkreten Testverfahren möglich.


4.5.3 Diskussion ausgewählter Ergebnisse

Bei den zentralen KFA-Variablen (AERGO, AERGM) finden sich keine irregulären Werte:

		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.

4.6 Übung

Führen Sie die restlichen Verteilungs- bzw. Fehleranalysen zu unserem Projekt aus. 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) Prüfen Sie für alle Variablen nach, 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 Variablenamen 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 35), 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, Stichprobenverteilungen der untersuchten Merkmale zu beschreiben, sondern strebt nach Aussagen über die Verteilungen in der Population. Bei einer kategorialen Verteilung 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 in unserer Projektdatei, 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 Statistics* 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 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% anzunehmen ist. Folglich müssen Sie auch eine **Intervallschätzung** abliefern. Deren Ergebnis bezeichnet man als **Konfidenz-** oder **Vertrauensintervall**.

Bei der geforderten statistischen Sicherheit (mit typischen Werten von 95% oder 99%) spricht man auch vom **Konfidenzniveau**, und das Gegenstück nennt man **Irrtumswahrscheinlichkeit** (mit typischen Werten von 5% oder 1%).

Bei der *Präzision* einer Intervallschätzung sind zwei Forderungen im Spiel:

- Das Konfidenzintervall soll möglichst klein sein.
- Das Konfidenzniveau soll möglichst groß sein.


Dummerweise verhalten sich die beiden Forderungen in gewissem Sinn 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 (siehe Abschnitt 4.8.3).

4.8.1 Vertrauensintervall verstehen und näherungsweise berechnen

Wir werden später das exakte Vertrauensintervall für eine Anteilsschätzung von SPSS berechnen lassen, wobei komplexe Algorithmen zum Einsatz kommen. Vorab lernen Sie einen Weg kennen, ein approximatives, aber in sehr vielen Fällen ausreichend genaues Vertrauensintervall auf sehr einfache Weise händisch (z.B. mit flinken Fingern auf einem Taschenrechner) zu ermitteln. Für die Beschäftigung mit dem manuellen Verfahren gibt es mindestens zwei gute Gründe:

- Sie gewinnen ein besseres Verständnis für die statistischen Grundlagen von Vertrauensintervallen.
- Sie gewinnen ein einfaches Verfahren, um schon bei der Planung einer Untersuchung für eine vorgegebene Vertrauensintervallbreite und ein gefordertes Konfidenzniveau den benötigten Stichprobenumfang berechnen zu können. Weil SPSS und auch G*Power vergleichbare Kalkulationen nicht anbieten, hat das Do-It-Yourself – Verfahren einen hohen praktischen Nutzen.

Wir untersuchen nun, wie sich die Anteilsschätzungen aus unendlich vielen Stichproben mit derselben, fest vorgegebenen Größe verhalten. Zunächst geht es um die Frage, von welcher Gestalt die Verteilung der Anteilsschätzungen aus unendlich vielen Stichproben ist. Sie können es glauben, nach wenigen Jahren Mathematikstudium beweisen (Stichwort: zentraler Grenzwertsatz) oder mit Hilfe eines Computer-Programms 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:



Was Sie hier sehen, ist eine simulierte Stichprobenverteilung für den Anteilsschätzer aus Stichproben der Größe $n = 31$ bei einer Populationswahrscheinlichkeit von $p = 0,806$.

Für das „Wunder“ der Normalverteilung von Anteilsschätzungen sind nur schwache, leicht realisierbare Voraussetzungen nötig (siehe Rumsey, 2008, S. 181). Für die Stichprobengröße n und die Wahrscheinlichkeit p müssen folgende Ungleichungen erfüllt sein:

$$n \cdot p \geq 5$$

$$n \cdot (1 - p) \geq 5$$

Wenn Sie die Wahrscheinlichkeit p nicht kennen, dürfen Sie zur Prüfung der beiden Voraussetzungen auch den Anteilsschätzer $\hat{p}$ aus Ihrer 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. Auf dem Weg zur Konstruktion eines Konfidenzintervalls für die Schätzung aus der einen vorhandenen Stichprobe spielt die Standardabweichung der Stichprobenverteilung eine entscheidende Rolle. Man spricht hier vom **Standardfehler** des Anteilsschätzers $\hat{p}$, und als Symbol wird anschließend $\sigma(\hat{p})$ verwendet.

Für konkrete Werte von n und p können Sie den Standardfehler zum Anteilsschätzer $\hat{p}$ mit der folgenden Formel berechnen:

$$\sigma(\hat{p}) = \sqrt{\frac{p \cdot (1-p)}{n}}$$

In der Praxis steht Ihnen statt der Populationswahrscheinlichkeit p aber nur eine Schätzung $\hat{p}$ aus Ihrer Stichprobe zur Verfügung, so dass Sie sich auch beim Standardfehler mit der Schätzung $\hat{\sigma}(\hat{p})$ zufrieden geben müssen:

$$\hat{\sigma}(\hat{p}) = \sqrt{\frac{\hat{p} \cdot (1-\hat{p})}{n}}$$

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:

$$[\mu - 1,96 \cdot \sigma; \mu + 1,96 \cdot \sigma]$$

Aufgrund dieser Einblicke in das Verteilungsverhalten von Anteilsschätzern aus Stichproben, sollten Ihnen die folgende Formel zur Berechnung des Vertrauensintervalls zu der Anteilsschätzung $\hat{p}$ aus einer konkreten Stichprobe (der einzig vorhandenen) plausibel erscheinen, obwohl wir uns einige Zwischenschritte bei der Herleitung erspart haben:

$$\left[\hat{p} - 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1-\hat{p})}{n}}; \hat{p} + 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1-\hat{p})}{n}} \right]$$

Für den Frauenanteil im *Statistischen Praktikum mit SPSS* ergibt sich so aus der Manuskriptstichprobe das folgende 95% - Vertrauensintervall:

$$\left[0,806 - 1,96 \cdot \sqrt{\frac{0,806 \cdot (1-0,806)}{31}}; 0,806 + 1,96 \cdot \sqrt{\frac{0,806 \cdot (1-0,806)}{31}} \right] = [0,667; 0,945]$$


4.8.2 Exaktes Vertrauensintervall von SPSS berechnen lassen

Nun sind Sie wahrscheinlich darauf gespannt, wie gut die approximative Lösung mit der exakten übereinstimmt:


- 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**, und markieren Sie im Rahmen **Konfidenzintervall** das Kontrollkästchen **Clopper-Pearson (exakt)**:



- 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:




- Wenn Sie schließlich im Dialog **Nichtparametrische Tests bei einer Stichprobe** auf **Ausführen** klicken, erscheint im Ausgabefenster die folgende Tabelle:

Übersicht über Hypothesentest


	Nullhypothese	Test	Sig.	Entscheidung
1	Die durch Geschlecht = (Frau) und (Mann) definierten Kategorien treten mit den Wahrscheinlichkeiten 0,5 und 0,5 auf.	Test auf Binomialverteilung einer Stichprobe	,001	Nullhypothese ablehnen.

Asymptotische Signifikanzen werden angezeigt. Das Signifikanzniveau ist ,05.

- Setzen Sie einen Doppelklick auf diese Tabelle, so dass die **Modellanzeige** erscheint. Mit diesem Dialog lassen sich weitere Ergebnisse (darunter das Konfidenzintervall) hervorzaubern:



- Wählen Sie im Bedienelement **Ansicht** (unten links) die **Konfidenzintervallübersicht**, um endlich das schon lange ersehnte Ergebnis bewundern zu können:



- Nach dem Schließen der **Modellanzeige** erscheint das Konfidenzintervall auch im Ausgabefenster:

Konfidenzintervall-Überblick

Konfidenzintervalltyp	Parameter	Schätzer	95% Konfidenzintervall.	
			Minimum	Maximum
Erfolgsrate der Binomialverteilung einer Stichprobe (Clopper-Pearson)	Wahrscheinlichkeit (Geschlecht= Frau).	,806	,625	,925

Das exakte Intervall weicht deutlich vom approximativen $[0,667; 0,945]$ ab. Das war zu erwarten, weil bei einer Stichprobe der Größe $n = 31$ und $\hat{p} = 0,806$ das im zentralen Grenzwertsatz


beschriebene Streben der Stichprobenverteilung in Richtung Normalität noch nicht abgeschlossen ist.

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 bei einer regelkonform durchgeführten Studie 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. Allerdings weicht die übliche Redeweise nur in harmloser Weise von der Logik der Vertrauensintervalle ab.

4.8.3 Stichprobenumfang für eine gewünschte Präzision berechnen

Man kann sich im Leben nicht immer alle Wünsche gleichzeitig erfüllen. Bei guter Planung und praller Brieftasche geht es aber manchmal doch. Eben mussten Sie zur Kenntnis nehmen, dass bei einer Studie zur möglichst präzisen Schätzung eines Populationsanteils bei fester Stichprobengröße n die beiden Aspekte von Präzision (statistische Sicherheit, kleines Intervall) negativ zusammenhängen.

Wird eine höhere statistische Sicherheit gefordert, ergibt sich ein breiteres Konfidenzintervall. Um das einzusehen, betrachten wir die Stichprobenverteilung des Anteils, von der wir mittlerweile wissen, dass sie bei angemessen 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 95% - Vertrauensintervalls

$$\left[\hat{p} - 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}}; \hat{p} + 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}} \right]$$

ändert sich der Faktor, mit dem der geschätzte Standardfehler $\hat{\sigma}(\hat{p})$ der Stichprobenverteilung multipliziert wird. 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 er 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 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 Spielerei:

$$n = z_{1-\alpha/2}^2 \frac{p \cdot (1-p)}{b^2}$$

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 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 ungünstigsten 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:


$$n = 1,96^2 \frac{0,5 \cdot (1-0,5)}{0,02^2} \approx 3,84 \frac{0,25}{0,0004} = 2400$$

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 zusammen gehörige 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 Abschnitt 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 große 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. 2500 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 20.

Wie schon erwähnt, sind die Dialogboxen beim Erstellen eines SPSS-Programms sehr nützlich. Mit Hilfe der bislang ignorierten Schaltfläche **Einfügen** kann die zu einer Dialogbox-Bearbeitung äquivalente Kommandofolge in ein Syntaxfenster übertragen werden. Sie müssen sich also nicht zwischen zwei unabhängigen SPSS-Bediensystemen entscheiden, sondern sollten 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 bei den Variablen GESCHL, FB, AERGO, AERGM, GEBJ, GROESSE und GEWICHT durch (vgl. Abschnitt 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 Startassistent (z.B. durch einen Mausklick auf den Schalter **Abbrechen**). Dabei erhalten Sie ein leeres Datenfenster 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 endet ebenfalls mit einem Punkt.

Noch sind die beiden Kommandos nicht ausgeführt worden, und das leere Datenblatt mit dem Namen **DatenSet0** ist immer noch die aktuelle Arbeitsdatei. Der Versuch, zur Produktion des ersten FREQUENCIES-Kommandos über dem Menübefehl

Analysieren > Deskriptive Statistik > 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 > Alles

Daraufhin werden folgende Aktionen ausgeführt:

- Es wird ein neues Datenblatt angelegt und zur Arbeitsdatei ernannt.
- Dorthin werden die Daten aus der angegebenen Datei kopiert.
- Das neue Datenblatt ist mit der Rohdatendatei **kfar.sav** verbunden (siehe Titelzeile des Dateneditorfensters).
- Das beim Programmstart vorhandene, leere Datenblatt mit dem Namen **DatenSet0** wird geschlossen.
- Das neue Datenblatt erhält den Namen **DatenSet1** und gelangt in den Vordergrund.

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 Symbolleistenschalter , oder drücken Sie die Tastenkombination **Strg+R**. Daraufhin werden alle Kommandos im Syntaxfenster ausgeführt, die (zu-
mindest teilweise) markiert sind.

Im Ausgabefenster protokolliert SPSS per Voreinstellung die verarbeiteten Kommandos in **Log-**Teilausgaben, falls Sie dieses Verhalten nicht per **Optionen**-Dialog auf der Registerkarte **Vie-****wer** abschalten (siehe Abschnitt 3.2.3). Außerdem protokolliert SPSS zu jeder Analyseanfor-
derung in der zunächst zugeklappten Teilausgabe **Anmerkungen** u.a. die zugrunde liegende Syn-
tax, z.B.:

Anmerkungen		
Ausgabe erstellt		22-MAY-2013 02:05:56
Kommentare		
Eingabe	Daten	U:\Eigene Dateien\SPSS\kfar.sav
	Aktiver Datensatz	DatenSet1
	Filter	<keine>
	Gewichtung	<keine>
	Aufgeteilte Datei	<keine>
	Anzahl der Zeilen in der Arbeitsdatei	31
Behandlung fehlender Werte	Definition von fehlenden Werten	Benutzerdefinierte fehlende Werte werden als fehlend behandelt.
	Verwendete Fälle	Statistik basiert auf allen Fällen mit gültigen Daten.
Syntax		FREQUENCIES VARIABLES=geschl fb /BARCHART FREQ /ORDER=ANALYSIS.
Ressourcen	Prozessorzeit	00:00:01,22
	Verstrichene Zeit	00:00:00,80

Damit sich durch spätere Wiederverwendung der SPSS-Kommandos der gewünschte Rationali-
sierungseffekt einstellen kann, müssen Sie Ihr SPSS-Programm sichern. Wechseln Sie dazu nöti-
genfalls zum Syntaxfenster, und wählen Sie den Menübefehl:

Datei > Speichern unter...

Verwenden Sie im Dateinamen die vorgeschlagene Erweiterung **.sps**, indem Sie *keine* Erweite-
rung 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 > Alles**
- 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 Datenset 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 Datenset 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** gesetzt. 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.

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 Dialogbox 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), Variablenamen usw. zusammensetzen, z.B.:

Kommandoname	→	FREQUENCIES
Spezifikationen	{	VARIABLES=geschl 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 Be-

deutung 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 bei Kommentaren) 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:

$$\frac{\text{Gewicht (in kg)}}{\text{Größe}^2 \text{ (in m)}}$$

In aktuellen Kapitel 6 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 Datendatei mit **kfar.sav** (*r* für *roh*) bezeichnet. Im Namen der Fertigdatendatei werden wir das **r** dann weglassen.

Wir werden im Verlauf des aktuellen Abschnitts 6 das SPSS-Transformationsprogramm zu unserem KFA-Projekt erstellen, indem wir passend konfigurierte Dialogboxen mit dem Schalter **Ein-**

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.

fügen quittieren, um die äquivalenten SPSS-Kommandos in einem Syntaxfenster zu sammeln (siehe Abschnitt 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 vorerst 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, z.B.:



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 abhän-

gige 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** (ein Variablenlabel) 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.
- Komplettern 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:



The screenshot shows the IBM SPSS Statistics Daten-Editor window for a file named '*kfar.sav [DatenSet1]'. The menu bar includes Datei, Bearbeiten, Ansicht, Daten, Transformieren, Analysieren, Direktmarketing, Diagramme, Extras, Fenster, and Hilfe. The toolbar contains various icons for file operations, data manipulation, and analysis. The main data grid shows 31 variables, with the first 11 visible: andere, smg, meth1, meth2, meth3, geschl, gebj, fb, groesse, gewicht, and Dekade. The 'Dekade' variable is the result of recoding 'gebj'. The status bar at the bottom indicates 'IBM SPSS Statistics Prozessor ist bereit'.

	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] → 1, (5, 10] → 2
Bei umgekehrter Anordnung derselben Ersetzungsregeln
(5 thru 10 = 2) (1 thru 5 = 1)
erhält man hingegen die Abbildung:
[1, 5) → 1, [5, 10] → 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.

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?

Umkodieren in andere Variablen: Alte und neue Werte

Alter Wert

☐ Wert:

☐ Systemdefiniert fehlend

☐ System- oder benutzerdefinierte fehlende Werte

☒ Bereich:

bis:

☐ Bereich, KLEINSTER bis Wert:

☐ Bereich, Wert bis GRÖSSTER:

☐ Alle anderen Werte

Neuer Wert

☒ Wert:

☐ Systemdefiniert fehlend

☐ Alte Werte kopieren

Alt -> Neu:

1 thru 3 -> 1
4 thru 6 -> 2

Hinzufügen
Ändern
Entfernen

☒ Ausgabe der Variablen als Strings Breite: 8

☐ Num. Strings in Zahlen umwandeln (*5->5)

Weiter Abbrechen Hilfe

Umkodieren in andere Variablen: Alte und neue Werte

Alter Wert

☐ Wert:

☐ Systemdefiniert fehlend

☐ System- oder benutzerdefinierte fehlende Werte

☒ Bereich:

bis:

☐ Bereich, KLEINSTER bis Wert:

☐ Bereich, Wert bis GRÖSSTER:

☐ Alle anderen Werte

Neuer Wert

☒ Wert:

☐ Systemdefiniert fehlend

☐ Alte Werte kopieren

Alt -> Neu:

2 thru 3 -> 1
4 thru 6 -> 2

Hinzufügen
Ändern
Entfernen

☒ Ausgabe der Variablen als Strings Breite: 8

☐ Num. Strings in Zahlen umwandeln (*5->5)

Weiter Abbrechen Hilfe

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 > Visuelles Klassieren

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) ein **Label** für die Zielvariable an:

Visuelles Klassieren

Liste der durchsuchten Variablen:

Name: Geburtsjahr [gebj]

Label: Geburtsjahr

Aktuelle Variable: gebj

Klassierte Variable: Dekade

Minimum: 1961

Nicht fehlende Werte

Maximum: 1975

Geben Sie Intervall-Trennwerte ein oder klicken Sie auf "Trennwerte erstellen", um automatische Trennwerte zu erstellen. Ein Trennwert von 10 beispielsweise definiert ein Intervall, das über dem vorangegangenen Intervall beginnt und bei 10 endet.

Gitter:

Wert	Beschreibung
1	HOCH
2	

Obere Endpunkte:

☒ Eingeschlossen (<=)

☐ Ausgeschlossen (<)

Trennwerte erstellen...

Beschreibungen erstellen

☒ Skala umkehren

OK Einfügen Zurücksetzen Abbrechen Hilfe

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:

Trennwerte erstellen

☒ Intervalle mit gleicher Breite

Intervalle - mindestens zwei Felder ausfüllen

Position des ersten Trennwerts:

Anzahl der Trennwerte:

Breite:

Position des letzten Trennwerts:

☒ Gleiche Perzentile auf der Grundlage der durchsuchten Fälle

Intervalle - eines der beiden Felder ausfüllen

Anzahl der Trennwerte: 1

Breite (%): 50,00

☐ Trennwerte bei Mittelwert und ausgewählten Standardabweichungen auf der Grundlage der durchsuchten Fälle

☐ +/- 1 Std.-Abw.

☐ +/- 2 Std.-Abw.

☐ +/- 3 Std.-Abw.

Durch "Zuweisen" werden die Trennwertdefinitionen durch diese Spezifikation ersetzt. Ein letztes Intervall enthält alle übrigen Werte: N Trennwerte führen zu N+1 Intervallen.

Zuweisen Abbrechen Hilfe

Im Hauptdialog werden nun die Trennwerte angezeigt, z.B.:

Visuelles Klassieren

Liste der durchsuchten Variablen:
 Geburtsjahr [gebj]

Name: gebj Label: Geburtsjahr

Klassierte Variable: Dekade Geburtsjahr(Klassiert)

Minimum: 1961 Nicht fehlende Werte Maximum: 1975

Geben Sie Intervall-Trennwerte ein oder klicken Sie auf "Trennwerte erstellen", um automatische Trennwerte zu erstellen. Ein Trennwert von 10 beispielsweise definiert ein Intervall, das über dem vorangegangenen Intervall beginnt und bei 10 endet.

Gitter:

	Wert	Beschriftung
1	1969,0	
2	HOCH	
3		

Obere Endpunkte
☒ Eingeschlossen (<=)
☐ Ausgeschlossen (<)

Trennwerte erstellen...
 Beschriftungen erstellen

☐ Skala umkehren

Durchsuchte Fälle: 31
 Fehlende Werte: 0

Klassen kopieren
 Aus einer anderen Variablen...
 Auf andere Variablen...

OK Einfügen Zurücksetzen Abbrechen Hilfe

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 Variante (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 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 *einzigsten* 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, diese 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.:

	lot11	lot12	motiv1	motiv2	motiv3	motiv4	motiv5	andere	smg	meth1	meth2	meth3	geschl	gebj	fb	groesse	gewicht	Dekade
1	4	2	1	0	0	0	0	0	1	1	2	3	1	1969	1	163	51,0	.
2	4	2	1	0	0	0	0	0	1	1	2	.	1	1970	1	158	56,0	.
3	3	2	0	0	0	0	0	1	1	4	.	.	1	1969	1	174	58,0	.
4	4	2	1	0	0	0	0	0	1	1	2	5	2	1967	1	182	77,0	.
5	4	1	1	0	0	0	0	0	1	3	2	4	1	1967	1	180	69,0	.

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 neue Variablen initialisiert, aber noch keine Werte ermittelt hat. In dieser Situation wird in der Statuszeile angezeigt, dass **Offene Transformationen** zur Bearbeitung anstehen. Sie können deren Ausführung erzwingen, indem Sie im Syntaxfenster ein EXECUTE-Kommando abschicken oder den folgenden Menübefehl wählen:

Transformieren > Offene 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)

$$\text{Gewicht (in kg)} = \overset{!}{\text{Größe (in cm)}} - 100$$

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 neu in die Arbeitsdatei aufzunehmende 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 (siehe unten) und spezielle Systemvariablen (z.B. **\$Casenum** für die fortlaufende Fallnummer in der Arbeitsdatei) in **Funktionsgruppen** geordnet zum Transport in

das Feld **Numerischer Ausdruck** an, so dass man bei der Verwendung von Funktionen das Nachschlagen und Tippfehler vermeiden kann.

Rufen Sie nun die Subdialogbox **Typ und Label** 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

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.

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.¹ Diese Funktionen lassen sich in mehrere Gruppen einteilen, aus denen 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 Absolutbetrag gebildet und in der neuen Variablen ABSRESID gespeichert.

- **Statistische Funktionen**, z.B.:

- | | |
|--|-----------------------|
| - MEAN[.n](<i>arg1</i> , <i>arg2</i> [, ...]) | Arithmetisches Mittel |
| - MEDIAN[.n](<i>arg1</i> , <i>arg2</i> [, ...]) | Median |
| - MAX[.n](<i>arg1</i> , <i>arg2</i> [, ...]) | Maximum |
| - MIN[.n](<i>arg1</i> , <i>arg2</i> [, ...]) | Minimum |
| - SD[.n](<i>arg1</i> , <i>arg2</i> [, ...]) | Standardabweichung |
| - SUM[.n](<i>arg1</i> , <i>arg2</i> [, ...]) | Summe |

Regeln:

- Die eckigen Klammern schließen optionale Angaben ein.
- Der optionale Funktionsparameter *n* hat folgende Bedeutung: Wenn bei einem Fall mindestens *n* valide Argumente vorliegen, wird der Funktionswert berechnet. Ansonsten wird dem Fall der Wert SYSMIS zugewiesen. Wird *n* 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 *n*:

- Punkt zwischen dem Funktionsnamen und *n* 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`

¹ SPSS kennt auch zahlreiche Funktionen für String- und Datums-Variablen, 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*.

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 wesentlichen 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, welcher 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
- 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 bequem 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 identischer Erwartungswerte 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 Gruppenvergleichen beschäftigen wir uns „offiziell“ in Abschnitt **Fehler! Verweisquelle konnte nicht gefunden werden.**

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. Ein alternativer Startwert, der andere Pseudozufallszahlen zur Folge hat, kann so gewählt werden:

- mit dem Menübefehl:

Transformieren > Zufallszahlengeneratoren

- oder mit dem SPSS-Kommando:

`SET SEED=n.`

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 Dezimal**punkt** 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** (z.B. als Konstante in einer Berechnungsanweisung) 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
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 (nötigenfalls rekodierten!) LOT-Variablen 1, 3, 4, 5, 8, 9, 11 und 12. Die restlichen Fragen 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 (Items) 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 2012b, 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 Test zur allgemeinspsychologischen Hypothese wird letztlich mit einem Einstichproben-t-Test geprüft, ob der Erwartungswert (Populationsmittelwert) der Variablen AERGZ signifikant größer als Null ist. Man kann den Test zwar bequem mit der SPSS-Prozedur zum t-Test für verbundene Stichproben durchführen, ohne die Variable AERGZ explizit berechnen zu müssen, doch bietet diese Prozedur keine Möglichkeit, die Normalverteilungsvoraussetzung des Tests (vgl. Abschnitt 7.1) zu prüfen. Daher berechnen wir AERGZ explizit und prüfen die für AERGZ bestehende Normalverteilungsvoraussetzung mit der Prozedur zur explorativen Datenanalyse (siehe Abschnitt 7.3).

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 **Fehler! Verweisquelle konnte nicht gefunden werden.**).

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.

- 3) Berechnen Sie aus dem Geburtsjahr der Untersuchungsteilnehmer das Alter.¹ 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 irgendwann das Wissen um das Alter der Befragten verloren geht.

6.5 Bedingte Datentransformation

Gelegentlich ist es erforderlich, eine Datenmodifikation auf diejenigen Fälle zu beschränken, die eine bestimmte Bedingung erfüllen. Wir benötigen z.B. im KFA-Projekt eine solche Möglichkeit, um bei den Motivations- und Methodenvariablen das bisher vertagte Problem der fehlenden Werte adäquat behandeln zu können (siehe Abschnitt 1.4.3.2).

Manchmal ist es angebracht, für mehrere disjunkte Teilmengen der Gesamtstichprobe jeweils spezifische Transformationen durchzuführen (Fallunterscheidung). Z.B. könnten man im Rahmen einer ernährungsphysiologischen Untersuchung bei der Berechnung des Idealgewichts aus der Körpergröße bei Frauen und Männern unterschiedliche Formeln anwenden.

In den SPSS - Transformations-Dialogboxen erreichen Sie über den Schalter **Falls** eine Subdialogbox 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 Werteauszählung (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 das MD-Problem bei den Motivationsvariablen gelöst 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.
- Menschen führen ein aufwändiges Verhalten nur aus, wenn sie einen Grund dafür haben.


Daher sollten für genau diese Fälle die Nullen bei den Variablen MOTIV1 bis MOTIV5 und ANDERE in SYSMIS umkodiert werden. Gehen Sie folgendermaßen vor:

¹ Bei Verwendung der Manuskriptstichprobe muss berücksichtigt werden, dass diese aus dem Jahr 2000 stammt.


- 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 Bildschirmphoto) 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 erscheint nach dem aussagenlogischen Axiom vom ausgeschlossenen Dritten als selbstverständlich, ist es aber in der empirischen Forschung z.B. wegen des nahezu allgegenwärtigen Problems fehlender Werte keineswegs. Generell kann z.B. der logische Ausdruck „GESCHL = 1“ folgende Wahrheitswerte annehmen:

- wahr $\Leftrightarrow$ Der GESCHL-Wert ist gleich Eins.
- falsch $\Leftrightarrow$ Der GESCHL-Wert ist eine von Eins verschiedene Zahl.
- unbestimmt $\Leftrightarrow$ Der GESCHL-Wert fehlt.

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 in obigem 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:

Symbol	Schlüsselwort	Bedeutung
=	EQ	gleich
<>	NE	ungleich
<	LT	kleiner als
<=	LE	kleiner oder gleich
>	GT	größer als
>=	GE	größer oder gleich

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 Wahrheitstabellen 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

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 obige Beispiel für einen zusammengesetzten logischen Ausdruck 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 1.4.3.2.4 vereinbart haben, legt im Einzelnen fest, was unter den möglichen Bedingungskonstellationen geschehen soll:

		Mindestens eine speziell interessierende Methode angegeben?	
		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.	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

Vergeben Sie für die Zielvariable den Namen POLYMOT sowie das Label *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** Eins 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-Problematik bei den Variablen MOTIV1 bis ANDERE bereits gelöst 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 der **Zählen**-Anweisung beachten: Ihre 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 **Label**-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.

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** selbstständig in ein neues Datenblatt einliebt, 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 = 2000 - 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 das optionale Variablenlabel 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 Transformationskommando eine bereits *vorhandene* Variable angesprochen, ist die Groß-/Kleinschreibung wiederum 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 Rohvariab-

len auf eine Anpassung der Voreinstellung Acht 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:

- o Breite der Datenfensterspalte (entspricht dem Dateneditorattribut **Spalten**)
- o Messniveau
- o 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 (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 oder 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 > Alles

Wenn alles glatt läuft, finden Sie anschließend im (aktiven) Ausgabefenster nur die protokollierten Kommandos.

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.:

IBM SPSS Statistics Daten-Editor - kfa.sav

Menü: Datei, Bearbeiten, Ansicht, Daten, Transformieren, Analysieren, Direktmarketing, Diagramme, Extras, Fenster, Hilfe

Sichtbar: 38 von 38 Variablen

	gebj	fb	grosse	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

Buttons: Datenansicht, Variablenansicht

Status: IBM SPSS Statistics Prozessor ist bereit

Außerdem sind die Attribute der neuen Variablen korrekt gesetzt:

IBM SPSS Statistics Variablenansicht - kfa.sav

	Name	Typ	Spaltenf...	Dezimal...	Variablenlabel	Wertelabels	Fehlende W...	Spalten	Ausrichtung	Messniveau	Rolle
31	Dekade	Numerisch	8	0		{1, 60er}...	Keine	7	Rechts	Ordinal	Eingabe
32	idgew	Numerisch	8	0	Idealgewicht na...	Keine	Keine	7	Rechts	Skala	Eingabe
33	lot	Numerisch	8	2	LOT-Optimismus	Keine	Keine	7	Rechts	Skala	Eingabe
34	aergam	Numerisch	8	1	Mittel der Ärger...	Keine	Keine	7	Rechts	Skala	Ziel
35	aergz	Numerisch	8	0	Ärger-Zuwachs ...	Keine	Keine	7	Rechts	Skala	Ziel
36	bmi	Numerisch	8	2	Body Mass Index	Keine	Keine	7	Rechts	Skala	Ziel
37	Alter	Numerisch	8	0		Keine	Keine	7	Rechts	Skala	Eingabe
38	polymot	Numerisch	8	0	Anzahl der Moti...	Keine	Keine	7	Rechts	Skala	Beide

Buttons: Datenansicht, Variablenansicht

Status: IBM SPSS Statistics Prozessor ist bereit

Das seit Beginn unserer Arbeit am Transformationsprogramm vorhandene, mit der Rohdatendatei verbundene Datenset 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 Prüfung der zentralen Projekt-Hypothesen

7.1 Grundprinzipien des statistischen Hypothesentests

In diesem Abschnitt werden einige Grundprinzipien der Inferenzstatistik 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. 2010, 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 Ärgerzuwachs

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 Differenzvariablen $\text{AERGZ} := \text{AERGM} - \text{AERGO}$, 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):

$$\mu_Z = \mu_M - \mu_O$$

7.1.2 Voraussetzungen für die Herleitung eines Hypothesentests

Wir setzen voraus, dass die Differenzvariable AERGZ in der Population normalverteilt ist mit dem Erwartungswert μ_Z und der Varianz σ_Z^2 :

$$\text{AERGZ} \sim N(\mu_Z, \sigma_Z^2)$$

Für die n AERGZ-Beobachtungen in der Stichprobe nehmen wir an, dass sie durch **unabhängiges** Ziehen aus der eben beschriebenen Population entstanden sind. Das schon in Abschnitt 1.1 betonte Unabhängigkeitsprinzip ist die zentrale Forderung in unserem **Stichprobenmodell** über die Gewinnung der empirischen Daten.

1.1.6 Teststatistik

7.1.2.1 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 zunehmender Effektstärke, die in unserem Fall folgendermaßen definiert ist (vgl. Abschnitt 1.3.2):

$$dz := \frac{\mu_Z}{\sigma_Z}$$

Die Teststatistik quantifiziert also, wie gut bzw. schlecht die Nullhypothese mit den Stichprobendaten vereinbar ist.

- 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 Nullhypothesenpopulation Zufallsstichproben mit einer Teststatistikausprägung größer oder gleich T_{emp} liefert. Ist diese Wahrscheinlichkeit sehr klein, liegt der Schluss nahe, dass die konkret vorliegende Stichprobe *nicht* aus einer Nullhypothesenpopulation stammt.

7.1.2.2 Die Prüfgröße zum t-Test für abhängige Stichproben

Für die mit Hilfe der Ärgerzuwachsvariablen formulierte KFA-Hypothese hat sich die folgende Teststatistik T_Z bewährt (mit Z als Abkürzung für AERGZ):

$$T_Z := \frac{\bar{Z}}{S_Z} \sqrt{n} \quad \text{mit} \quad \bar{Z} := \frac{1}{n} \sum_{i=1}^n Z_i \quad \text{und} \quad S_Z := \sqrt{\frac{1}{n-1} \sum_{i=1}^n (Z_i - \bar{Z})^2}$$

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) eine t-Verteilung mit $n - 1$ Freiheitsgraden. Damit kennen wir das Verhalten der Teststatistik immerhin *am Rand* der Nullhypothese. Dieses Wissen genügt, wie sich gleich zeigen wird.

Bevor wir uns dem Testentscheid unter Verwendung der t-Test – Prüfgröße zuwenden, beobachten wir noch, dass diese Teststatistik einem vertrauten Konstruktionsprinzip 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.

7.1.3 Überschreitungswahrscheinlichkeit und Entscheidungsregel

Weil die Verteilung der Teststatistik T_Z für Stichproben aus einer Population mit $\mu_Z = 0$ bei beliebigem Nebenparameter σ_Z^2 bekannt ist, kann man zu dem in einer konkreten Stichprobe erzielten Wert T_{emp} die folgende **Überschreitungswahrscheinlichkeit** bestimmen:

Mit welcher *maximalen* Wahrscheinlichkeit nimmt die Teststatistik T_Z bei einer Zufallsstichprobe der Größe n aus einer **Nullhypothesenpopulation** einen Wert größer oder gleich T_{emp} an?

Wir scheinen vor einem Problem zu stehen, weil unsere Nullhypothese ($\mu_Z \leq 0$) unendliche viele Verteilungen enthält, so dass entsprechend viele Überschreitungswahrscheinlichkeiten zu betrachten sind. Allerdings kann man leicht zeigen, dass die Überschreitungswahrscheinlichkeit am Rand der Nullhypothese (also bei $\mu_Z = 0$) maximal wird. Es genügt also, die Überschreitungswahrscheinlichkeit für ($\mu_Z = 0$) zu betrachten.

Diese Wahrscheinlichkeit wollen wir mit $P_{H_0}(T_Z \geq T_{\text{emp}})$ bezeichnen. Sie wird von SPSS berechnet und in der Ausgabe zum t-Test für verbundene Stichproben mit **Sig.** überschrieben.

SPSS berichtet 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 wird sich aber gleich zeigen, dass man die einseitige Überschreitungswahrscheinlichkeit leicht aus der zweiseitigen berechnen kann.

Bei einem akzeptierten **Fehlerrisiko erster Art** von $\alpha = 5\%$ verwendet man die folgende **Entscheidungsregel**:

$$P_{H_0}(T_Z \geq T_{\text{emp}}) \begin{cases} \geq 0,05 & \Rightarrow H_0 \text{ beibehalten} \\ < 0,05 & \Rightarrow H_0 \text{ verwerfen} \end{cases} \quad (7-1)$$

Die Nullhypothese wird also abgelehnt, wenn die Teststatistik in der beobachteten Stichprobe einen Wert annimmt, der bei Zufallsstichproben aus einer H_0 -Population (genauer: bei $\mu_Z = 0$), nur relativ selten (mit einer Wahrscheinlichkeit kleiner 0,05) erreicht oder übertroffen wird.

7.1.4 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:


$$T_{\text{emp}} \begin{cases} \leq T_{\text{krit}} & \Rightarrow H_0 \text{ beibehalten} \\ > T_{\text{krit}} & \Rightarrow H_0 \text{ verwerfen} \end{cases} \quad (7-2)$$

T_{krit} ist in unserer Situation 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 Überschrei-

tungswahrscheinlichkeiten ausgeben, 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:



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 .

Wir kommen zu einer Testentscheidung, indem wir unser Stichprobenergebnis T_{emp} vor dem Hintergrund dieses Erwartungshorizonts beurteilen. Wir lehnen die Nullhypothese ab, wenn sie als Generator unserer Daten unplausibel ist.

7.1.5 Das akzeptierte Risiko erster Art

Wenn wir aus einer Nullhypothesenpopulation (genauer: bei $\mu_Z = 0$) eine Zufallsstichprobe der Größe $n = 31$ ziehen und T_{emp} ermitteln, werden wir mit der Wahrscheinlichkeit $\alpha = 0,05$ einen Wert größer $T_{krit} = 1,70$ erhalten und falsch gegen die H_0 entscheiden, also einen **Fehler erster Art** begehen. Der α -Wert sollte umso niedriger angesetzt werden, je gravierender (schädlicher, teurer) das irrtümliche Ablehnen einer gültigen Nullhypothese ist.

7.1.6 Einflussgrößen 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 $\frac{\mu_Z}{\sigma_Z}$ (vgl. Abschnitt 1.3.2).

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 $P_{H_0}(T_Z \geq T_{emp}) < 0,05$ bzw. $T_{emp} > T_{krit}$, also eine korrekte Entscheidung gegen die H_0 .

- **Akzeptierter α -Fehler**

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 t-Test für verbundene Stichproben passiert, wenn bei gültiger Alternativhypothese ($\mu_z > 0$) die Stichprobengröße n steigt:

- o Der Quotient $\frac{\bar{Z}}{S_z}$ konvergiert stochastisch gegen $\frac{\mu_z}{\sigma}$, also gegen eine feste Zahl > 0 .
- o Die Prüfgröße

$$T_z := \frac{\bar{Z}}{S_z} \sqrt{n}$$

wächst.

- o 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 verwerfen zu können.

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 AERGZ 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 erwünschte Teststärke (z.B. $1 - \beta = 0,8$) die erforderliche Stichprobengröße ermitteln.

7.1.7 Das zweiseitige 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 sein α -Niveau einhält, sind kritische Werte $T_{\text{krit},2}$ so zu bestimmen, dass gilt:

$$P_{H_0}(|T_Z| \geq |T_{\text{krit},2}|) = \alpha$$

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.:

$$P_{H_0}(|T_Z| \geq |T_{\text{emp}}|) \begin{cases} \geq 0,05 & \Rightarrow H_0 \text{ beibehalten} \\ < 0,05 & \Rightarrow H_0 \text{ verwerfen} \end{cases} \quad (7-3)$$

7.1.8 Einseitige Überschreitungswahrscheinlichkeit aus der zweiseitigen bestimmen

Weil unsere Teststatistik unter der H_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) keinesfalls 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 11.4.4.1).

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* Regression besonders bequem mit Hilfe der Stichprobenkorrelation r zwischen Kriterium und Regressor notieren lässt:

$$T_r := \frac{r\sqrt{n-2}}{\sqrt{1-r^2}}$$

Als Effektstärkemaß zur differentialpsychologischen Hypothese 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 datenunabhängigen Faktor $(n-2)$ ein Schätzer für die Effektstärke. Damit zeigt die Prüfgröße T_r (bei passendem Vorzeichen) 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.

Für methodisch besonders Interessierte soll noch eine alternative Darstellung für T_r vorgeführt werden, die von eher anwendungsorientierten Lesern gefahrlos übersprungen werden kann. Weil der Stichprobenschätzer b_1 des Steigungskoeffizienten in folgender Beziehung zur Stichproben-

korrelation 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:

$$T_r = b_1 \frac{\hat{\sigma}_X}{\hat{\sigma}_Y} \frac{\sqrt{n-2}}{\sqrt{1-r^2}} = \frac{b_1}{\hat{\sigma}_{b_1}}$$

7.2.2 Annahmen

Die Annahmen im Modell der bivariaten linearen Regression werden anschließend der bequemeren Schreibweise halber für ein Kriterium Y und einen Regressor X beschrieben.

Um verbreiteten Missverständnissen entgegen zu wirken, ist zunächst zu betonen:

- Es wird keine Annahme über die Verteilung des Regressors gemacht.
- Es wird keine Annahme über die *univariate* Verteilung des Kriteriums (die so genannte Randverteilung) gemacht.
- Es sind die **Residuen des Modells**, welche die gleich zu erläuternden Verteilungsvoraussetzungen (Normalität, Varianzhomogenität, Unabhängigkeit) 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 also auf der **Regressionsgeraden** durch die Punktepaare

$$(X, \beta_0 + \beta_1 X)$$

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 (mit Erwartungswert 0 und Varianz σ^2). 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.

Eine Verletzung der Unabhängigkeit ist bei unserer querschnittlich angelegten Studie mit Einzelpersonen als Untersuchungseinheiten nicht zu erwarten. Begründete Zweifel an der Unabhängigkeitsannahme bestehen in folgenden Situationen:

- Zeitreihen-Stichproben (z.B. Arbeitsmarktdaten aus 40 aufeinander folgenden Jahren)
Zu Regressionsmodellen für seriell abhängige Daten siehe z.B. Baltes-Götz (2013c).
- Cluster-Stichproben (z.B. 300 Schüler aus insgesamt 20 Schulklassen)
In einem solchen Fall kann man die Gruppenzugehörigkeit als (kategorialen) Regressor behandeln oder eine so genannte **Mehrebenen-Analyse** durchführen (siehe z.B. Baltes-Götz 2013b).

7.3 Verteilungsanalyse für die abgeleiteten 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, AERGZ und BMI. U.a. kümmern wir uns um die gemäß Abschnitt 7.1 beim t-Test für verbunde-


ne 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:

7.3.1 Diagnose von Ausreißern

Als **Ausreißer** bezeichnet man sehr große oder kleine 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 beliebte 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.


7.3.2 Die SPSS-Prozedur zur explorativen Datenanalyse

Für die eben geplanten Aufgaben (Ausreißerdiagnose und Verteilungsprüfung bei intervallskalierten Variablen) 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.

Wir erhalten im Ausgabefenster u.a. für jede abhängige Variable einen **Boxplot**.

7.3.3 Ergebnisse 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 Ärgertemperatur 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 10), deklarieren wir den betroffenen Wert (= -4) kurzerhand als MD-Indikator. Auf diese Weise findet sich doch noch eine Gelegenheit, im Kurs die Deklaration von benutzerdefinierten MD-Indikatoren zu üben. Markieren Sie in der Variablenansicht des Datenfensters die Zelle mit den **Fehlenden Werten** der 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.

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 „ansschlägt“, ist jedoch von einer relevanten Verletzung der Normalitätsannahme auszugehen.

Aufgrund der problematischen Verteilungsverhältnisse entscheiden wir uns, 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). Dieser Test 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.

Weil der Vorzeichentest weit weniger empfindlich auf Ausreißer reagiert als der parametrische t-Test, können wir den 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.







Die bisherige Diskussion der AERGZ-Verteilung hat sich auf Gefahrenquellen für die Interpretierbarkeit des geplanten zentralen Hypothesentests konzentriert. Es ist jedoch keinesfalls verboten, sondern sogar dringend empfohlen, sich anhand obiger Verteilungsdiagramme und sonstiger deskriptiver Informationen einen Eindruck von der empirischen Bewährung der KFA-Hypothese

¹ Leider kollidiert die Bezeichnung mit der oben eingeführten Abkürzung für unsere Ärgerzuwachsvariable.

zu verschaffen. Das AERGZ-Histogramm spricht für einen starken KFA-Effekt in der erwarteten Richtung. Eine genaue Kenntnis des deskriptiven Ergebnisbilds kann verhindern, dass wir von einem durch technische Defekte verfälschten Testergebnis in die Irre geführt werden.

7.3.4 Ergebnisse 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:



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.


7.4 Prüfung der differentialpsychologischen Hypothese

7.4.1 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 ausgeschlossenen studentisierten Residuen (interne Variable SDRESID) gegen die standardisierte Modellprognose (interne Variable ZPRED)
Weil die Modellprognose eine lineare Funktion des Regressors ist, erhalten wir letztlich einen Plot der ausgeschlossenen-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 ausgeschlossenen-studentisierten Residuen wünschenswert, doch sind relevante Unterschiede zwischen den beiden Residualdiagrammen kaum 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 7.3.3). 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 Abwesenheit von Ausreißern ab 100 Fällen eine Verletzung der die Normalverteilung der Residuen „weniger problematisch“.

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 unserer fiktiven Situation.

Wer sich ausführlich über die lineare Regressionsanalyse mit SPSS informieren möchte, kann ein ZIMK-Manuskript zu diesem Thema (Baltes-Götz 2013c) auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen finden:

IT-Services (ZIMK) > Infos für Studierende > EDV-Dokumentationen >
Statistik > Lineare Regressionsanalyse mit SPSS

7.4.2 Methodologische Anmerkungen

7.4.2.1 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 9.4 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.

7.4.2.2 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 Nullhypothese interpretiert werden, doch spricht es gegen die Existenz eines *starken* Effekts. Um zu ge-

naueren Aussagen zu kommen, betrachten wir die Power unseres t-Tests bei unterschiedlichen Effektstärken in der Population.


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 > Wissenschaftliche Programme > 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.

7.4.2.3 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 2012b) auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen finden:


IT-Services (ZIMK) > Infos für Studierende > EDV-Dokumentationen >
Statistik > Behandlung fehlender Werte in SPSS und Amos

7.5 Prüfung der 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 7.3.3 haben wir uns entschieden, statt des ursprünglich geplanten parametrischen t-Tests für abhängige Stichproben den nichtparametrischen **Vorzeichentest** zu verwenden. 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

		N
Ärger mit kontrafaktischer Alternative - Ärger ohne kontrafaktische Alternative	Negative Differenzen ^a	2
	Positive Differenzen ^b	26
	Bindungen ^c	3
	Gesamt	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

Statistik für Test^a

	Ärger mit kontrafaktischer Alternative - Ärger ohne kontrafaktische Alternative
Z	-4,347
Asymptotische Signifikanz (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:

Statistik für Test^a

	Ärger mit kontrafaktischer Alternative - Ärger ohne kontrafaktische Alternative
Z	-4,347
Asymptotische Signifikanz (2-seitig)	,000
Exakte Signifikanz (2-seitig)	,000
Exakte Signifikanz (1-seitig)	,000
Punkt-Wahrscheinlichkeit	,000

a. Vorzeichentest

Zur Beurteilung der empirischen Effektstärke ziehen wir trotz schiefer Verteilung den Mittelwert und die Standardabweichung von AERGZ heran, schließen aber den in Abschnitt 7.3.3 diagnostizierten extremen Wert aus. Die folgende Tabelle stammt von der in Abschnitt 7.3.2 beschriebenen Prozedur zur explorativen Datenanalyse:

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 in Abschnitt 1.3.2.4 vorgestellten 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.

7.6 Übung

Für die Differenzvariable (GEWICHT - IDGEW) akzeptieren beide Normalverteilungstests die Nullhypothese (vgl. Abschnitt 7.3):

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 IDGEW 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 Ergebnisse werden im nächsten Abschnitt vorgestellt.

7.7 Arbeiten mit dem Ausgabefenster (Teil II)

Unter dem *Pivotieren* einer Tabelle versteht SPSS u.a. die folgenden Operationen:

- Austauschen ihrer Zeilen-, Spalten- und Schichtendimensionen
- Änderung der Schachtelungsordnung
- Gruppierungen von Kategorien vornehmen oder aufheben
- Kategorien 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.

7.7.1 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.

Wenn der Tabelleneditor in einem separaten Fenster



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

Test bei gepaarten Stichproben									
		Gepaarte Differenzen				T	df	Sig. (2-seitig)	
					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 folgende Dialogfeld benötigt:



Es enthält je eine Ablagezone für die Zeilen, Spalten und Schichten der Tabelle und je einen Eintrag mit Pivot-Symbol  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 obiger Übung 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.

7.7.2 Dimensionen verschieben

Durch das Verschieben ihres Pivot-Eintrags kann man für eine Dimension neu festlegen, ob ihre Kategorien durch Spalten, Zeilen oder Schichten dargestellt werden sollen, z.B.:

		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

In SPSS 15 war es noch zuverlässig möglich, unerwünschte Gruppierung folgendermaßen zu beseitigen:

- Rechtsklick auf das Kategorienetikett
- Aus dem Kontextmenü wählen: **Gruppierung aufheben**

In SPSS 21 gelingt es zwar, die Gruppenzelle **Paaren 1** der Beispieltabelle mit der beschriebenen Kontextmenü-Option zu entfernen,

		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

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:

Test bei gepaarten Stichproben		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	
	Untere	-11,5924
	Obere	-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
- Kontextmenü zu einer markierten Kategorie öffnen und Option **Gruppe** wählen
- Beschriftung der Gruppenzelle nach Doppelklick anpassen

In der folgenden Version unserer Tabelle wurde eine Gruppe mit den drei Kategorien zum t-Test gebildet:

		Körpergewicht t (in kg) - Idealgewicht nach der Formel Größe - 100
Mittelwert		-9,3226
Standardabweichung		6,1881
Standardfehler des Mittelwertes		1,1114
95% Konfidenzintervall der Differenz	Untere	-11,5924
	Obere	-7,0528
	T	-8,388
Signifikanztest	df	30
	Sig. (2-seitig)	,000

Außerdem wurde das Gruppennetikett vertikal zentriert über das Registerblatt **Ausrichtung und Ränder** der per Kontextmenü der Gruppenzelle erreichbaren Dialogbox mit den **Zelleneigenschaften**.

Selbst definierte Gruppierungen lassen sich über das Kontextmenü-Item **Gruppierung aufheben** wieder entfernen.

Dass bei der Arbeit mit dem Pivot-Editor Zellbegrenzungen spontan auftauchen oder verschwinden, gehört seit einigen Generationen zu den Eigenarten des Programms. Weil die Endredaktion der Tabellen in der Regel in einem Textverarbeitungsprogramm erfolgt und dort ungehindert möglich ist, kann man mit diesem Fehler leben.

7.7.4 Kategorien aus- bzw. einblenden, verschieben oder vertauschen

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 (in kg) - Idealgewicht nach der Formel Größe - 100
Mittelwert			-9,3226
Standardabweichung			6,1881
95% Konfidenzintervall der Differenz	Untere		-11,5924
	Obere		-7,0528
Signifikanztest	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:



- Maustaste loslassen

Zum *Einblenden* von vorher abgeschalteten Kategorien kenne ich (neben **Bearbeiten > Rückgängig**) nur die global wirksame Methode:

Ansicht > Alle Kategorien einblenden

Kategorien lassen sich per Drag & Drop verschieben oder vertauschen:

- Kategorie markieren (siehe obige Beschreibung zum Ausblenden von Kategorien)
- Mit der Maus auf die Markierung klicken und die Maus bei gedrückter linker Taste bewegen
- Über zulässigen Zielorten hat der Mauszeiger die folgende Gestalt:
- Lässt man am Zielort die Maustaste los, erscheint ein Menü, das ein Verschieben oder Vertauschen erlaubt:

Einfügen vor
Vertauschen

7.7.5 Zellen modifizieren

Text editieren

Bei aktivem Pivot-Editor können Sie nach einem Doppelklick auf eine Zelle den enthaltenen Text beliebig ändern. In unserem Beispiel sollte der Titel etwas informativer und die Beschriftung der rechten Spalte etwas sparsamer werden. Außerdem sollten wir konsistent mit der Hypothesenformulierung (siehe Abschnitt 7.6) die *einseitige* Überschreitungswahrscheinlichkeit angeben. Im aktuellen Beispiel wirkt sich allerdings das Halbieren der betragsmäßig sehr kleinen Zahl auf den ersten drei Dezimalstellen nicht aus:

t-Test zum Vergleich von Real- und Idealgewicht			Realgewicht - Idealgewicht
Mittelwert			-9,3226
Standardabweichung			6,1881
95% Konfidenzintervall der Differenz	Untere		-11,5924
	Obere		-7,0528
Signifikanztest	T		-8,388
	df		30
	Sig. (1-seitig)		,000

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.

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

Um die Anzahl der Dezimalstellen anzupassen, kann man so vorgehen:

- Alle betroffenen Zellen markieren
- Dialogbox **Zelleneigenschaften** per Kontextmenü öffnen
- Auf der **Formatwert**-Registerkarte die gewünschte Anzahl der **Dezimalstellen** eingeben


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.

7.7.6 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			-9,3226
Standardabweichung			6,1881
95% Konfidenzintervall der Differenz	Untere		-11,5924
	Obere		-7,0528
	T		-8,388
Signifikanztest	df		30
	Sig. (1-seitig)		,000

8 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.

8.1 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.

8.2 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 Varianzhomogenität		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	-,25062
	Varianzen sind nicht gleich			-2,133	6,937	,071	-2,05895	,96530	-4,34576	,22787

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.


8.3 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 Residuen an. Nach dem Menübefehl


Analysieren > Regression > Linear

wählen wir die **abhängige Variable** BMI und die **unabhängige Variable** GESCHL:




Hätten wir eine String-Variable 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 keinen Anlass zur Sorge bzgl. der Normalverteilungsannahme:



Die über eine **explorative Datenanalyse** (siehe Abschnitt 7.3.2) für die abgespeicherten ausgeschlossen-studentisierten Residuen (siehe Abschnitt 7.4.1) 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-Testergebnis wieder, dessen Interpretierbarkeit mittlerweile bestätigt ist:

Koeffizienten ^a								
Modell		Nicht standardisierte Koeffizienten		Standardisierte Koeffizienten	T	Sig.	95,0% Konfidenzintervalle für B	
		Regressions- koeffizient 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 wegen folgender Vorteile für gleich große Teilstichproben sorgen:

- Der t-Test erreicht seine optimal Power bei fixem Gesamtstichprobenumfang.
- Es besteht eine bessere Robustheit gegenüber Verletzungen der Homoskedastizität.

Bei einer vorhandenen Stichprobe ist es für solche Optimierungsbemühungen zu spät.

8.4 Empirische Effektstärke

Signifikanztests hängen stark vom Stichprobenumfang ab und sollten 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 beim 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: $d = 0,8$

Zur Schätzung der empirischen Effektstärke eignet sich bei homogenen Varianzen und unterschiedlichen Stichprobenumfängen die folgende Formel mit der gepoolten Standardabweichung im Nenner:

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.


$$\hat{d} := \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{(n_1 - 1)\hat{\sigma}_1^2 + (n_2 - 1)\hat{\sigma}_2^2}{n_1 + n_2 - 2}}}$$

Für unser Beispiel erhalten wir einen starken Effekt:

$$\hat{d} = \frac{22,8078 - 20,7488}{\sqrt{\frac{(6-1)4,7304 + (25-1)3,5852}{6+25-2}}} = \frac{2,059}{1,9449} = 1,05866104$$

8.5 Graphische Veranschaulichung


Zur graphischen Veranschaulichung des Geschlechtsunterschieds beim BMI eignet sich z.B. das folgenden 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 benennen Sie neben der abhängigen Variablen BMI den Faktor GESCHL:




9 Streudiagramme

Wir haben schon einige graphische Darstellungsmöglichkeiten kennen gelernt, die im Rahmen von Statistikprozeduren angeboten werden (z.B. Balkendiagramm, Kreisdiagramm, Histogramm, Boxplot). In aktuellen Abschnitt arbeiten wir erstmals mit dem **Diagramme**-Menü und vor allem mit dem Diagramm-Editor zur individuellen Nachbearbeitung von Diagrammen.

SPSS-Einsteiger werden vermutlich durch das **Diagramme**-Menü leicht irritiert, weil hier gleich *drei* Zugänge angeboten werden:



Über **veraltete 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 **Diagramm-Editor** modifiziert werden können. Seit SPSS 17 ist über die **Grafiktafel-Vorlagenauswahl** 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 neuen **Grafiktafel-Editor** bearbeitet. Ein Blick in das Benutzerhandbuch zu SPSS 21 (siehe IBM Corp. 2012b, S. 320) 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 Abschnitt 9 lernen Sie das Streudiagramm inklusive der Optionen zur Erstellung und Nachbearbeitung kennen. In Abschnitt 11.2 wird per Diagramm-Editor ein spezielles Balkendiagramm gestaltet.

9.1 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 **veralteten Dialogfeld**.

9.1.1 Diagrammerstellung


Nach dem Menübefehl

Diagramme > 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**.
- Ziehen Sie das Symbol  zum **gruppierten Streudiagramm** auf die **Diagramm-vorschau** (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 **Diagramm-erstellung** 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 **Zuweisen**.

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 9.2 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 Graphik 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.


Eine GPL-Dokumentation wird mit SPSS ausgeliefert und ist zusätzlich im Internet frei verfügbar (IBM Corp. 2011c). Im Kurs kann die GPL aus Zeitgründen nicht behandelt werden.

9.1.2 Dialogbox Einfaches Streudiagramm


Wer sich mit der **Diagrammerstellung** noch nicht anfreunden kann, hat in der SPSS-Version 21 auch noch die **veralteten Dialogfelder** zur Verfügung, z.B. zum Erstellen eines Streudiagramms:

Diagramme > Veraltete 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 9.2).

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 veralteten Dialogfeld leichter als mit der Diagrammerstellung (siehe Abschnitt 9.1.1). 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 9.1.1).

9.1.3 Grafiktafel-Vorlagenauswahl


Bei der Arbeit mit der Diagrammerstellung wählt man zunächst einen Diagrammtyp und besetzt anschließend die dort vorhandenen Rollen durch geeignete Variablen. Bei der Arbeit mit der Grafiktafel-Vorlagenauswahl 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 Diagrammvorlagen zu erstellen, die in der Grafiktafel-Vorlagenauswahl von SPSS Statistics genutzt werden können und bei entsprechender Passung in der Vorschlagsliste für eine bestimmte Konstellation von ausgewählten Variablen erscheinen.

Nach dem Menübefehl


Diagramme > Grafiktafel-Vorlagenauswahl

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 **Detail**-Angaben machen, z.B. eine Markierungsvariable wählen.


Öffnet man im Ausgabefenster ein per Grafiktafel-Vorlagenauswahl erstelltes Diagramm, erscheint der **Grafiktafel-Editor**, z.B.:



Er bietet im Vergleich zum Diagramm-Editor (siehe Abschnitt 9.2) sehr eingeschränkte Möglichkeiten und erlaubt z.B. nicht das Ergänzen einer Regressionsgeraden. Wir werden die Graphiktafel-Technik in diesem Kurs nicht benutzen.

9.2 Streudiagramm per Diagramm-Editor modifizieren

Wenn Sie im Ausgabefenster einen Doppelklick auf ein Diagramm setzen, das per **Diagrammerstellung** oder über ein **veraltetes Dialogfeld** entstanden ist, wird es im **Diagramm-Editor** geöffnet:



Anschließend werden am Beispiel des Streudiagramms einige allgemeine Bedienungsmöglichkeiten des Diagramm-Editors 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 9.1.1) FNR zur **Punktbeschriftungsvariablen** ernannt haben:

- Mausklick auf den Schalter 
- oder Menübefehl **Elemente > Datenbeschriftungen ausblenden**

Bei Verwendung des veralteten Dialogfelds (vgl. Abschnitt 9.1.2) sind die Datenbeschriftungen trotz analoger Vorgehensweise per Voreinstellung ausgeblendet.

9.2.1 Eigenschaftsfenster

Zum aktuell im Diagramm-Editor 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 **Zuweisen** erscheint das Ergebnis:





9.2.2 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.:




9.2.3 Menüs und Symbolleisten

Viele Angebote sind über die Untermenüs zu den Items **Optionen** und **Elemente** im Graphikeditor-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.

Über das Symbol  oder den Menübefehl

Elemente > Anpassungslinie bei Untergruppen

erhält man gruppenspezifische (geschlechtsbedingte) Regressionsgeraden:



Man erkennt in der Graphik 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 zu bei zwei Frauen mit derselben Größendifferenz. Nach dieser Vermutung *moderiert* Geschlecht den Effekt der Größe auf das 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 2009a), das auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen zu finden ist:

IT-Services (ZIMK) > Infos für Studierende > EDV-Dokumentationen >
Statistik > Moderatoranalyse per multipler Regression mit SPSS

Überflüssige Objekte lassen sich über ihr Kontextmenü oder (im markierten Zustand) per **Entf**-Taste löschen.

9.2.4 Beschriftungen

Bei vielen Beschriftungen lässt sich nach dem Markieren die Größe des umgebenden Rechtecks über acht Anfassers 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* Anfassers, 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 Graphik 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.

9.3 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 Diagramm-Editor 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 veraltetes Dialogfeld (siehe Dialogbox **Einfaches Streudiagramm** in Abschnitt 9.1.2)
- 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\21\Looks\APA_Styles.sgt'.
```

SPSS 21 enthält im Ordner **C:\Program Files\IBM\SPSS\Statistics\21\Looks** einige Diagrammvorlagen, z.B. die Vorlage **APA_Styles.sgt** für Diagramme nach den Richtlinien der **American Psychological Association (APA)**:



9.4 Übung

Nach dem „Scheitern“ der differentialpsychologischen Hypothese (siehe Abschnitt 7.4) 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 2009a) 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.

10 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.

10.1 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 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 sonst (also bei falschem oder 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:



Filter wirken sich nur bei statistischen und graphischen 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 Datenblatt kopieren**

Man erhält ein neues Datenblatt mit den Positiv-Fällen.

- **Nicht ausgewählte Fälle löschen**

Die Negativ-Fälle 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.

10.2 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 10.1) und fordert dann über

Analysieren > Berichte > Fälle zusammenfassen

die gewünschte Auflistung an:



Wir erhalten die folgende Liste:

Zusammenfassung von Fällen^a

	Fallnummer	Ärger ohne kontrafaktisch e Alternative	Ärger mit kontrafaktisch er Alternative
1	4	6	2
2	15	2	1
Insgesamt N	2	2	2

a. Begrenzt auf die ersten 100 Fälle.

11 Analyse von Kreuztabellen

Wir wollen die Hypothese prüfen, dass weibliche und männliche Hochschulaspiranten unterschiedliche Präferenzen bei der Wahl ihres Studienfachs haben.

11.1 Untersuchungsplanung

Unsere Fachbereichsvariable (FB) enthält Information über die Studienfächer der Untersuchungsteilnehmer(innen) 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

Nachdem die Begriffe aus der eingangs formulierten inhaltlichen Hypothese hinreichend präzisiert sind, können wir die empirisch zu prüfenden *Nullhypothese* formulieren:

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 (gleich 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 einseitige Hypothesen möglich (siehe Abschnitt 11.4.4.2). 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 der Zusammenhang zwischen den beiden *nominalskalierten* Merkmalen Fachbereich und Geschlecht zu untersuchen ist, wählen wir als Auswertungsmethode die Kreuztabellenanalyse mit χ^2 -Test. Diese Methode ist recht beliebt, wobei Einsatzfälle gelegentlich durch das wenig empfehlenswerte künstliche Kategorisieren von metrischen Variablen erzwungen werden. Hoffentlich trägt die ausführliche Behandlung der Methode im aktuellen Abschnitt 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 zur Verfügung steht, der ebenfalls nominales Messniveau besitzt (Geschlecht).

Bei sehr vielen Fragestellungen werden aber Methoden benötigt, die ...

- eine beliebige Anzahl von Prädiktoren erlauben,
- das vorhandene Messniveau der Variablen unterstützen, also die enthaltene Information komplett verwerten,
- eine flexible Modellierung erlauben (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 2012a), das auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen zu finden ist:

[IT-Services \(ZIMK\)](#) > [Infos für Studierende](#) > [EDV-Dokumentationen](#) >
[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 2012b, S. 55):

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 scheint mir diese Technik fragwürdig, 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 nur SPSS-Interessierte enthalten sind. 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 finden Sie 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 > Programme > Wissenschaftliche Programme > GPower

G*Power arbeitet bei der Kreuztabellenanalyse mit dem folgenden Effektstärkeindex W (nach Cohen 1988, S. 216)

$$W := \sqrt{\sum_{i=1}^z \sum_{j=1}^s \frac{(p_{ij}^{(1)} - p_{ij}^{(0)})^2}{p_{ij}^{(0)}}}$$

Hier werden normierte Diskrepanzen zwischen den Zellwahrscheinlichkeiten $p_{ij}^{(1)}$ unter der Alternativhypothese und den Zellwahrscheinlichkeiten $p_{ij}^{(0)}$ unter der Nullhypothese über alle Zellen der betrachteten Kreuztabelle aufsummiert. In Abschnitt 11.4.1 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 keine Informationen über die Effektstärke in der Population verfügbar sind, nehmen wir einen *mittleren* Wert von $W = 0,3$ nach der von Jacob Cohen (1988, S. 227) vorgeschlagen 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 11.4.1.

Es resultiert eine erfreulich hohe Power von 0,99:




11.2 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 (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 Kontingenztafel anfordern:



Aufgrund dieser Spezifikationen erhalten wir für unsere Stichprobe die folgende Kreuztabelle¹:

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
	% 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	13	18	49	22	20	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%

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 Verteilung der Fachbereichs-Variablen:

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:

¹ Die Tabelle wurde mit dem Pivot-Editor (vgl. Abschnitt 7.7) durch Aufheben der Gruppierung Geschlecht und gekürzte Kategorienbeschriftungen etwas schlanker gemacht.


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.


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 Diagramm-Editor (vgl. Abschnitt 9.2) vergeben wir per **Eigenschaften**-Dialog zunächst die **X-Achsen** – Rolle an die Variable FB (**Zuweisen** 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:




Bei restlichen Schritten:


- 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 die **erste Unterteilung** 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**.

11.3 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.

11.4 Testverfahren

11.4.1 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:

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

$$\hat{p}_{i.} := \frac{n_{i.}}{n}$$

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.

Mit der geschätzten Wahrscheinlichkeit $\hat{p}_{ij}^{(0)}$ ergibt sich also 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:

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.

$$\frac{(2010 - 2000)^2}{2000} = 0,05$$

Der χ_p^2 -Wert ist also offenbar, wie es in Abschnitt 7.1.2.1 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 $z \cdot s$ Zellen) und $\frac{m_{ij}}{n}$ als geschätzter Wahrscheinlichkeit $\hat{p}_{ij}^{(0)}$ der Zelle (i, j) unter der Nullhypothese zeigt sich ein sehr enger Bezug zwischen Pearsons χ_p^2 -Prüfgröße und dem Effektstärkeindex W (vgl. Abschnitt 11.1):


$$\chi_p^2 = \sum_{i=1}^z \sum_{j=1}^s \frac{(n_{ij} - m_{ij})^2}{m_{ij}} = n \sum_{i=1}^z \sum_{j=1}^s \frac{\left(\frac{n_{ij}}{n} - \frac{m_{ij}}{n}\right)^2}{\frac{m_{ij}}{n}} = n \sum_{i=1}^z \sum_{j=1}^s \frac{(\hat{p}_{ij}^{(1)} - \hat{p}_{ij}^{(0)})^2}{\hat{p}_{ij}^{(0)}} = n\hat{W}^2$$

Die aus einer Stichprobe berechnete Prüfgröße χ_p^2 ist also im Kern ein Schätzer für die 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 7.1.2.1, 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:



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.

Zur Beurteilung der empirischen Effektstärke wählen wir zusätzlich **Phi und Cramer-V** (siehe Abschnitt 11.4.2).

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^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^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^2 -Test klar gegen die H_0 . In Abschnitt 7.1 wurde dieses Argumentationsmuster der Inferenzstatistik ausführlich erläutert.

Neben der χ^2 -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 -Statistik nach Pearson wegen der besseren Verteilungsapproximation zu bevorzugen (siehe z.B. Hartung 1989, S. 439). Damit ist es also vertretbar, die χ^2 -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 - 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 -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:

$$\chi_{MH}^2 := r^2(n-1)$$

Üblicherweise gilt der Mantel-Haenszel - Test als anwendbar, sofern beide Variablen mindestens ordinale Skalenqualität besitzen (siehe z.B. Norušis 2011b). Da wir zwei kategoriale Variablen betrachten, ist diese Statistik bei unserer Tabelle auf jeden Fall sinnlos.

11.4.2 Schätzung der Effektstärke

Zur Beurteilung der empirischen Effektstärke haben wir in der Kreuztabellen-Subdialogbox **Statistik** (siehe Abschnitt 11.4.1) **Phi und Cramer-V** gewählt.

Der bei (2×2) -Tabellen als Zusammenhangsmaß taugliche **Phi-Koeffizient** wird mit Hilfe von Pearsons χ_P^2 -Statistik folgendermaßen definiert:

$$\phi := \sqrt{\frac{\chi_P^2}{n}}$$

Nach einer Rechnung aus Abschnitt 11.4.1 ist ϕ damit ein Schätzer für die Populations-Effektstärke W (vgl. Abschnitt 11.1):

$$\phi = \hat{W}$$

Bei einer Kreuztabelle mit

$$q := \text{Min}(z, s) > 2$$

haben W und ϕ einen maximalen Wert

$$\sqrt{q-1}$$

größer als Eins (Cohen 1988, Abschnitt 7.2). In der Definition von Cramers V wird folgendermaßen für den Maximalwert Eins gesorgt:

$$V := \sqrt{\frac{\chi_P^2}{n(q-1)}} = \sqrt{\frac{\chi_P^2}{n}} \frac{1}{\sqrt{q-1}} = \hat{W} \frac{1}{\sqrt{q-1}}$$


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. Nominalmaß	Phi	,254	,003
	Cramer-V	,254	,003
Anzahl der gültigen Fälle		283	

Er ist nicht weit entfernt vom Wert 0,3, den wir in Abschnitt 11.1 für den Effektstärkeindex W angenommen haben.

1.1.7 Einzelvergleiche der Spaltenanteile

Nachdem die Nullhypothese identischer Frauenanteile in den Fachbereichen der Universität Trier gescheitert ist, 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% gehalten wird. Allerdings ist das von SPSS angewendete Bonferroni-Verfahren sehr konservativ, weil auf die Bonferroni-Holm-Verfeinerung verzichtet wird (siehe Baltes-Götz 2013c).

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

11.4.3 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) > Infos für Studierende > EDV-Dokumentationen >
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 7.7) geöffnet und 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 Fünf 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 (mit $z \neq 2$ oder $s \neq 2$) verwendet, sofern er zulässig ist, sollte seine 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 11.1).

11.4.4 Besonderheiten bei (2 × 2) - Tabellen

11.4.4.1 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)**

11.4.4.2 Einseitige Hypothesen

Bei einer (2 × 2) - Tabelle lässt sich auch eine einseitige (gerichtete) 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 10) 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 11.4.4.1 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.

11.4.4.3 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 11.4.4.1 ist sie allerdings irrelevant, weil in der (2×2) -Situation Fishers exakter Tests in jedem Fall zu bevorzugen ist.

12 Fälle gewichten

Per Voreinstellung bezieht SPSS bei statistischen Auswertungen *alle* Fälle mit dem Gewicht *Eins* ein. In Abschnitt 10 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.


12.1 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 11. 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 11 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 Eins in die Kreuztabellenanalyse eingehen. Wenn die vorhandenen Beobachtungen individuelle Gewichte ($\neq 1$) erhalten, werden natürlich Signifikanztests erheblich beeinflusst. Auf jeden Fall muss dann die Gewichtungsvariable einen Mittelwert von 1 haben, d.h. die Summe der Gewichte muss gerade den Stichprobenumfang ergeben.

12.2 Übung

Prüfen Sie anhand der Daten aus der Tabelle am Anfang von Abschnitt 12.1 die Nullhypothese, dass die Merkmale Geschlecht und Fachbereich unabhängig sind.

13 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 *eine Familie* inhaltlich verwandter dichotomer 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 13.4).

13.1 Mehrfachantworten-Sets 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 > Mehrfachantworten-Sets definieren

In der nun erscheinenden Dialogbox sind folgende Aktionen nötig:

¹ Alternativ können Sie auch den folgenden Menübefehl verwenden:
Analysieren > Tabellen > Mehrfachantworten-Sets

- 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** Eins.
- 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 **Mehrfachantworten-Sets** auf, und quittieren Sie die Dialogbox mit **OK**.

Auf die beschriebene Weise definierte Mehrfachantworten-Sets 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 **Mehrfachantworten-Sets 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 > Variablen-Sets 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).

13.2 Häufigkeitstabellen für Mehrfachantworten-Sets


Unter Verwendung der Variablengruppe \$MOTIVE (erzeugt per MRSETS-Kommando) lässt sich die in Abschnitt 13.1 präsentierte Tabelle mit den Häufigkeitsverteilungen der Set-Variablen über den Menübefehl

Analysieren > Tabellen > 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 Mehrfachwahl-Sets 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 Mehrfachwahl-Set, 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 1.4.3.2.3). Für diese Befragungstechnik stellt sich nun eine weitere Begründung heraus.


Das folgende Balkendiagramm mit den Zustimmungsteilen für alle Motivvariablen




lässt sich über den Menübefehl

Diagramme > Veraltete Dialogfelder > Balken


erstellen. Nach Wahl der Variante (**Einfach, Auswertung über verschiedene Variablen**)



legt man die teilnehmenden Variablen fest,



ändert die **Statistik**



und erledigt letzte Korrekturen im Diagramm-Editor (Farbe der Balken, Beschriftung der Y-Achse).

Im konkreten Beispiel trat bei Verwendung des generell empfehlenswerten Zwischenablagentyps **Bild (Erweiterte Metadatei)** auf dem Weg vom SPSS-Viewer zu Microsoft Word ein Beschriftungsdefekt auf,

Eigene Studie Bewerbung um Stelle Bewerbung um HIWI-Job Interesse an der EDV Interesse an Statistik Andere Motive

der sich durch die Wahl einer größeren Schrift vermeiden lies.

13.3 Kreuztabellen für Mehrfachantworten-Sets

Wenn wir uns für Geschlechtsunterschiede bei der Zustimmung zu den fünf konkreten Motiven interessieren (z.B.: Wer interessiert sich mehr für Statistik?), sind genau *fünf* (2×2) - Tabellen zu analysieren. Über den aus Kapitel 11 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
		% von Interesse an Statistik	75,0%	25,0%	100,0%
		% von Geschlecht	62,5%	83,3%	66,7%
	Ja	Anzahl	9	1	10
		% von Interesse an Statistik	90,0%	10,0%	100,0%
		% von Geschlecht	37,5%	16,7%	33,3%
Gesamt	Anzahl	24	6	30	
	% von Interesse an Statistik	80,0%	20,0%	100,0%	
	% 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%	1	3,3%
	Bewerbung um HIWI-Job	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%	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 Kombi-tabelle mit der Essenz aus sechs (2×2) - Kontingenztabellen.


Um die obige Tabelle anzufordern, öffnen wir über

Analysieren > Tabellen > Benutzerdefinierte Tabellen

erneut die Dialogbox für benutzerdefinierte Tabellen. Ausgehend von dem in Abschnitt 13.2 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 **Gesamtergebnis**. So resultiert schließlich die oben gezeigte Tabelle.

Auch bei den Kreuztabellen ist die in Abschnitt 13.2 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.

13.4 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 13.2 und 13.3 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.

14 Datendateien im Textformat einlesen

Gelegentlich sind Daten auszuwerten, die in Textdateien vorliegen. Dabei können zwei Dateiformate auftreten:

- 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).
- separierte Daten
Für jeden Fall liegen alle Variablen in derselben Reihenfolge vor, wobei zwischen zwei Werten ein Trennzeichen steht.

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-pos.txt** und **kfar-kv-sep.txt** mit positionierten bzw. separierten KFA-Daten von 77 Fällen. Es bietet sich an, diese Daten einzulesen, um die in Abschnitt 9.4 durch graphische Datenexploration gewonnene Moderatorversion der differentialpsychologischen Hypothese anhand einer unabhängigen Stichprobe zu überprüfen.

14.1 Import von positionierten Textdaten (feste Breite)

In der Datei **kfar-kv-pos.txt** 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:¹


Textimport-Assistenten starten und Datei auswählen

Nach dem Start des Textimport-Assistenten ist zunächst die Eingabedatei zu wählen:



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:

¹ Achtung: Mit der deutschen SPSS-Version 20.0.0.1 für Windows mit 64-Bit-Architektur ist bei meiner Beispieldatei der Importassistent beim Schritt 4 gescheitert (siehe unten). Anschließend wird der Import durch die Version 19 beschrieben.




Von der Möglichkeit, in der **ersten Zeile der Datei die Variablennamen** zu transportieren, wird in unserem Beispiel kein Gebrauch gemacht.

Wenn der Assistent nach Schritt 2 die Arbeit verweigert,




hilft es vielleicht, über **Bearbeiten > Optionen > Allgemein** die Unicode-Unterstützung aus-
zuschalten:



Damit dies möglich ist, darf kein gefülltes Datenblatt vorhanden sein.


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:



Mit SPSS 21 ließen sich nach der Spalte 27 keine Trennlinien mehr per Mausklick einfügen:




Nach der numerischen Eingabe einer **Spaltennummer** klappte immerhin der Schalter **Trennung einfügen**.

Schritt 5

Im fünften Assistentenschritt können Sie die von SPSS erkannten bzw. vorgeschlagenen Variablennamen 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

Der Assistent bietet zwei Möglichkeiten zum Konservieren einer Dateispezifikation:

- **Dateiformat für zukünftige Verwendung speichern?**
Es entsteht eine Textassistenten-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:



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=TXT
  /FILE="U:\Eigene Dateien\SPSS\kfar-kv-pos.txt"
  /FIXCASE=2
  /ARRANGEMENT=FIXED
  /FIRSTCASE=1
  /IMPORTCASE=ALL
  /VARIABLES=
  /1 geschl 4-4 F1.0
  V2 5-12 8X
  /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
  V17 21-27 7X.
CACHE.

```

Nach dem Einlesen einer Textdatei dürfen Sie auf keinen Fall die Deklaration der dort eventuell verwendeten **MD-Indikatoren** vergessen. Dies sollte per Syntax mit dem Kommando MISSING VALUES geschehen, z.B.:

```
MISSING VALUES geschl lot1 to lot12 (9).
```

In der Datei **kfar-kv-pos.txt** sind allerdings alle Fälle komplett.

Weil das Kommando MISSING VALUES (nicht nur beim Einlesen von Textdaten) von großer Bedeutung ist, soll seine allgemeine Syntax noch beschrieben werden:

MISSING VALUES { <i>varlist</i> ALL} (<i>valuelist</i>) [[/]{ <i>varlist</i> ALL} ...]
--

varlist Dieser Platzhalter steht für eine Liste vorhandener Variablen, deren MD-Indikatoren festgelegt werden sollen (vgl. Abschnitt 16.1.5.2).

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

14.2 Import von separierten Daten Textdaten


Separierte Textdaten lassen sich erheblich bequemer importieren als positionierte, zumal sie üblicherweise durch eine Zeile mit den Variablennamen eingeleitet werden. Die Datei **kfar-kv-sep.txt** enthält dieselben KFA-Daten, die in Abschnitt 14.1 aus einer positionierten Datei gelesen wurden:

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	...
.	.	.	.	.	.	.	.	.	.	...
.	.	.	.	.	.	.	.	.	.	...

Beim Import der separierten KFA-Textdaten informieren wir den über


Datei > Textdaten lesen

gestarteten Assistenten im zweiten Schritt 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

In der Datei **kfar-kv-sep.txt** kommt als Trennzeichen nur der **Tabulator** zum Einsatz:



Schritt 5

Im fünften Assistentenschritt müssen wir nur prüfen, ob die automatische Erkennung des **Datenformats** erfolgreich war:



Schritt 6

Im letzten Assistentendialog werden die schon in Abschnitt 14.1 vorstellten Optionen zum Konservieren der Importspezifikation angeboten.

Auch nach dem Einlesen von separierten Textdaten dürfen Sie auf keinen Fall die Deklaration der eventuell vorhandenen **MD-Indikatoren** vergessen. Dies sollte per Syntax mit dem Kommando MISSING VALUES geschehen, das in Abschnitt 14.1 beschrieben wird, z.B.:

MISSING VALUES geschl lot1 to lot12 (9).

In der Datei **kfar-kv-sep.txt** sind allerdings alle Fälle komplett.

14.3 Überprüfung der revidierten differentialpsychologischen Hypothese

Um mit den in Abschnitt 14.1 bzw. Abschnitt 14.2 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 ($p = 0,307$ im Test für den Produktterm):

a

Modell	Nicht standardisierte Koeffizienten		Standardisierte Koeffizienten	T	Sig.	95,0% Konfidenzintervalle für B	
	Regressionskoeffizient 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

Abhängige Variable: Mittel der Ärger-Variablen

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.


15 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:




15.1 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 die Variablenlisten trotz der Größen-variablen Dialogboxen eventuell etwas unübersichtlich, z.B.:



Mit der Option **Namen anzeigen** im Bereich **Variablenlisten** kann man auf die kompaktere Darstellung *ohne* Labels umschalten, z.B.:




- Die Variablen sind angeordnet wie in der Arbeitsdatei, was in der Regel ein bequemes Arbeiten erlaubt. Gemeinsam zu analysierende und damit in Dialogboxen auszuwählende Variablen stehen nämlich oft in der Arbeitsdatei hintereinander. Bei der Arbeit mit einer unbekannten Datendatei findet man (namentlich bekannte) Variablen jedoch leichter bei alphanumerischer Sortierung.

Sprache der Ausgabe bzw. Benutzeroberfläche

SPSS erlaubt für die **Ausgabe** (Beschriftung der Tabellen) und für die **Benutzeroberfläche** (Menüs und Dialogboxen) die Wahl zwischen diversen Sprachen.

15.2 Beschriftung der Ausgabe

Auf dem Registerblatt **Beschriftung der Ausgabe** können Sie z.B. veranlassen, dass in Pivot-Tabellen vorhandene Wertelabels ignoriert und stattdessen die Werte selbst angezeigt werden:



15.3 Datei-Speicherstellen

Auf dem Registerblatt **Datei-Speicherstellen** kann man u.a. einstellen:

Startordner für die Dialogfelder zum Öffnen und Speichern

Auf den Pool-PCs an der Universität Trier eignet sich der Ordner

U:\Eigene Dateien\SPSS

Sitzungs-Journal

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 für Anwender(innen) mit „Mut zur SPSS-Syntax“ 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 **Sitzungs-Journal** den voreingestellten Öffnungsmodus **Anhängen** abändern auf **Überschreiben**. Dann wird die Journaldatei zu Beginn jeder Sitzung neu erstellt, wobei gegebenenfalls der alte Inhalt überschrieben wird.

16 Anhang

16.1 Weitere Hinweise zur SPSS-Kommandosprache

In Kapitel 5 wurden nur sehr oberflächliche Hinweise zur SPSS-Kommandosprache gegeben. Diese sollten genügen für Anwender(innen), 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. 2500 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 20.


16.1.1 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.

- **Dateidefinitions-Kommandos**

Sie dienen zum Einlesen von Daten in die Arbeitsdatei. Als Beispiel haben wir bereits 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, graphische 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 Pseudo-zufallszahlengenerators 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

SPSS-Programme können flexibel gestaltet werden:

- In einem Programm dürfen beliebig viele Prozedur-Kommandos auftreten. Manche Anwender leben in dem Irrglauben, pro SPSS-Programm sei nur eine einzige Statistikprozedur erlaubt, und verstreuen daher zusammenhängende Auswertungen über unübersichtlich viele Miniprogramme. Andere haben den falschen Ehrgeiz, ihr gesamtes Projekt in einem einzigen Programm abzuwickeln, und erstellen dabei ein unpraktisches Monsterprogramm mit mehreren hundert Zeilen. Wie so oft im Leben ist auch hier der gesunde Mittelweg zu empfehlen: Für abgrenzbare Aufgabenpakete sollte jeweils ein eigenes Programm erstellt werden (z.B. mit allen Prozeduren zur Datenprüfung).
- Auch *nach* einer Prozedur dürfen Datentransformationen vorgenommen werden.
- Man kann nach einer Prozedur sogar weitermachen mit der Definition einer neuen Arbeitsdatei, welche dann die alte ersetzt.

16.1.4 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.

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.

16.1.5 Regeln für Variablenlisten

16.1.5.1 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!

16.1.5.2 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,
varname_1,
varname_2 Variablennamen

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. (2009a). *Moderatoranalyse per multipler Regression mit SPSS*. Online-Dokument: <http://www.uni-trier.de/index.php?id=22528>
- Baltes-Götz, B. (2012a). *Logistische Regressionsanalyse mit SPSS*. Online-Dokument: <http://www.uni-trier.de/index.php?id=22513>
- Baltes-Götz, B. (2012b). *Behandlung fehlender Werte in SPSS und Amos*. Online-Dokument: <http://www.uni-trier.de/index.php?id=23239>
- Baltes-Götz, B. (2013a). *R-Pakete und -Syntax in SPSS verwenden*. Online-Dokument: <http://www.uni-trier.de/index.php?id=44476>
- Baltes-Götz, B. (2013b). *Analyse von hierarchischen linearen Modellen mit der SPSS-Prozedur MIXED*. Online-Dokument: <http://www.uni-trier.de/index.php?id=39127>
- Baltes-Götz, B. (2013c). *Lineare Regressionsanalyse mit SPSS*. Online-Dokumentation: <http://www.uni-trier.de/index.php?id=22489>
- 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. (1995). *Forschungsmethoden und Evaluation*. Berlin: Springer.
- 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.
- Eid, M., Gollwitzer, M. & Schmitt, M. (2010). *Statistik und Forschungsmethoden*. 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. (2009). *Discovering Statistics Using SPSS* (3rd 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. (2011c). *GPL Reference Guide for IBM SPSS Visualization Designer*. Online-Dokument: <http://publib.boulder.ibm.com/infocenter/spssstat/v20r0m0/index.jsp>
- IBM Corp. (2012a). *IBM SPSS Data Preparation 21*. Online-Dokument: <http://pic.dhe.ibm.com/infocenter/spssstat/v21r0m0/index.jsp>
- IBM Corp. (2012b). *IBM SPSS Statistics 21 Core-System-Benutzerhandbuch*. Online-Dokument: <http://pic.dhe.ibm.com/infocenter/spssstat/v21r0m0/index.jsp>
- 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: https://www.ibm.com/developerworks/mydeveloperworks/wikis/home?lang=en#/wiki/We70df3195ec8_4f95_9773_42e448fa9029/page/Books%20and%20Articles
- 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>
- München, R.A. (2013). *The Popularity of Data Analysis Software*. Online-Dokument: <http://r4stats.com/articles/popularity/> (abgerufen: 2013.02.24).
- 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
- Tabachnik, B.G. & Fidell, L.S. (2007). *Using multivariate statistics* (5th ed.). Boston: Pearson.
- Wallis, W.A. & Roberts, H.V. (1956). *Statistics, a new approach*. Glencoe, Ill.: The Free Press.
- Wentura, D. (2004). Ein kleiner Leitfaden zur Teststärke-Analyse. Online-Dokument: <http://www.uni-saarland.de/fak5/excops/download/POWER.pdf>

Stichwortregister

A

Ablehnungsbereich	149
Achsenteilstriche	193
ALLBUS	6
Alpha-Fehler	8, 13, 148
Alphanumerische Variablen	28
Alternativhypothese	2, 146
American Psychological Association	198
Amos	37, 166
AND-Operator	135
Angelpunkte	155
Anwärterliste	73
APA	198
Arbeitsdatei	50
speichern	61
Artefakt	11
Assistent	
zum Textimport	238
Ausblenden	
von Kategorien	176
Ausgabeblock	79
Ausgabefenster	39, 78, 170
designtes	83
Mehrere verwenden	83
Neues anfordern	83
Ausreißer	85, 155
Ausrichtung	53
Automatisierte Datenerfassung	45

B

Balkendiagramme	74
Bedienoberfläche	101
Bedingte Datentransformation	132
Beobachtungseinheit	6
Berichte	203
Beta-Fehler	8, 13, 149
Body Mass Index	131
Bonferroni	220
Boxplot	155

C

CAPI	48
CATI	48
Chi-Quadrat-Statistik	215
COMMENT-Kommando	110
COMPUTE-Kommando	124, 126
COUNT-Kommando	137
Cramers V	218, 219

D

Data Collection Data Entry	37
Data Preparation	70
DATASET NAME	104
Dateidefinitions-Kommandos	255
Daten suchen	90
Datenblatt	49
Datendatei	
Öffnen	71
Sichern	61
Dateneditor	23, 48
Dateneditorfenster	39
Dateneingabe	65
Datenerfassung	45
automatisierte	45
manuelle	32, 47
per Datenbankprogramm	47
per SPSS-Dateneditor	48
Datenlexikon	49
Datenmatrix	23
Datenschutz	24
Daten-Set	49
Datensicherheit	112
Datentransformation	9, 111
bedingte	132
Datumsvariablen	28
Deklarationsteil	49
Demographische Merkmale	19
Determinationskoeffizient	18
Dezimalstellen	52
in Pivot-Tabellen	177
Dezimaltrennzeichen	129
Diagrammerstellung	186
Diagrammvorschau	187
Dienst-Kommandos	255
Differentialpsychologische Hypothese	199
DIW	6
DO IF	132
DO IF - Kommando	237
DO REPEAT - Kommando	237

E

Effektstärke	14, 149, 168, 182, 207, 218, 219
EFS Survey	46
Eigenschaftsfenster	193
Einfügen	
Fall	66
Variable	57
Einseitige Hypothesen	

für (2 × 2) - Tabellen	224	Pseudozufallszahlgeneratoren	128
Einseitiger Test	19	RND	127
Einstellungen modifizieren	249	SD	127
Ein-Stichproben-t-Test	131	SQRT	127
Erfassungsfehler	69	statistische	127
Exact Tests - Modul	221	SUM	127
Exakte Tests	221	UNIFORM	128
Excel	47	VALUE	128
EXECUTE-Kommando	117, 123	G	
Explorative Datenanalyse	155, 156	G*Power 3.1	13, 17, 165, 207, 224
Exportieren	82	Generalisierbarkeit	13, 75
Externe Validität	13, 75	GENESIS	6
F		Gerichtete Hypothese	19
Fall		GESIS	6
einfügen	66	GET DATA - Kommando	243
erschieben	67	GET-Kommando	104
löschen	67	GGRAPH-Kommando	185
Fälle		GPL	185, 188
auflisten	203	Grafiktafel-Editor	191
ausfiltern	201	Grafiktafel-Vorlagenauswahl	190
gewichten	226	Graphics <i>Programming</i> Language	185, 188
Fälle auswählen	201	GRAPH-Kommando	185
Fallidentifikation	23	Gruppenbildung	114
Falls-Subdialogbox	132	Gruppenvergleiche	179
Fallstudien	42	Gruppierungen	
Fehlende Werte	28, 128	in einer Pivot-Tabelle	173
Rechenregeln für ...	130	Gruppierungsfaktor	7
Fehler		GSS	6
erster Art	8, 148	H	
zweiter Art	8, 149	Haltepunkt	108
Fertigdatendatei	64, 111	Handbücher	43
Filter	201, 202	Häufigkeitsanalyse	72, 75
FILTER_\$	202	Hauptausgabefenster	83
Filterführung	48	Hilfesystem	40
Fishers exakter Test	152, 224	Histogramm	83
Fokus		Homogenitätshypothese	214
im Ausgabefenster	78	Homoskedastizität	154
FORMATS-Kommando	142	Hypothesen	5, 8
FREQUENCIES-Kommando	101, 105	Hypothesentests	2, 146
Funktionen	127	I	
ABS	127	ICR	47
arithmetische	127	Inferenzstatistik	146
EXP	127	Initialisierung numerischer Variablen	113
für fehlende Werte	128	Internet	44
LN	127	Interquartilsbereich	85, 155
MAX	127	Intervallniveau	11
MEAN	127	Intervallschätzung	2
MEDIAN	127	J	
MIN	127	Journaldatei	251
NMISS	128		
NORMAL	128		

K

Kategorien	
ausblenden	176
verschieben	176
Kategorienliste	26
KFA-Hypothese	10
Klassenbildung	7
Kodierplan	9, 22, 33
Kodierung	27
Kolmogorov-Smirnov - Test	157, 158
Kommandosprache	101, 109, 236, 252
Kommentare in SPSS-Programmen	110, 142
Konfidenzintervall	2
Kontinuitätskorrektur nach Yates	225
Kreuztabellen	205
Kritischer Wert	148
Kurtosis	86

L

Leerzeilen	142
Lernprogramm	41
Levene-Test	180
Life Orientation Test	16
Likelihood-Quotienten-Test	für
Kreuztabellen	218
Linearitätsannahme	153
Logische Operatoren	135
Logischer Ausdruck	134, 135, 201
Auswertungsreihenfolge	136
unbestimmter	134
Wahrheitstafeln	136
Löschen	
Fall	67
Variable	58
LOT	119

M

Mantel-Haenszel-Statistik	218
MAXQDA	27
MD-Indikator	28
Median	84
Mediator	4
Mehrebenenanalyse	6
Mehrebenen-Analyse	154
Mehrfachantworten-Set	25, 26
Mehrfachwahl	
Häufigkeiten	228
Kreuztabellen	234
Mehrfachwahlfragen	228
sparsames Set aus kateg. Variablen	25
vollständiges Set aus dichot. Variablen	24
Mehrfachwahl-Fragen	24

Mehrfachwahl-Set

definieren	228
Menüzeile	39
Messniveau	54
Messwiederholungsfaktor	7
MISSING VALUES - Kommando	244, 257
Missing-Data-Indikator	28
Mittelwert	84
Modellierung	3
Moderatoreffekt	197
Modus	84
MRSETS	229
MULT RESPONSE	230

N

Navigationsbereich	78, 79
Nichtparametrischer Lagevergleich	159
NMISS	139
Nominalskalenniveau	28
Normalitätsannahme	154
Normalverteilung	93
Normalverteilungsannahme	158
Normalverteilungstests	157, 158
NOT-Operator	135
Nullhypothese	2, 146
Numerische Funktionen	<i>Siehe Funktionen</i>
Numerische Variablen	27
Numerischer Ausdruck	126
Auswertungsprioritäten	129

O

OCR	47
Offene Fragen	26
Offene Transformationen	124
Öffnen	
Datendatei	71
OMR	47
Online-Datenerhebung	45
Operationalisierung	7
Ordinatenabschnitt	17, 153
OR-Operator	135

P

Parameterschätzung	1
Pearsons Chi-Quadrat-Statistik	215
PERMISSIONS	113
Phi-Koeffizient	219
Pivot-Editor	170
Plausibilitätsprüfungen	48
Population	1
Positionierte Daten	238
Power	13, 150
t-Test zum Regressionskoeffizienten	164

Poweranalyse		SPSS-	
Post hoc	164	Syntax	109
Pretest	35	SPSS Data Collection Data Entry	48
Probabilistische Gesetze	1	SPSS im Internet	44
Programm-orientierte Arbeitsweise	103	SPSS-Datendatei	
Prozedur-Kommandos	255	Öffnen	71
Prüfgröße	146	Sichern	61
Pseudozufallszahlengenerator	129	SPSS-Kommandosprache	101, 109
Punktschätzung	2	SPSS-Programm	64, 101, 102
Q		dialogunterstützte Erstellung	103
Qualitativen Datenanalyse	27	Standardabweichung	85
Questback	46	Standardfehler	94, 147
R		der Schiefe	86
R 32		Startassistent	38
Ratingskalen	11	Statistik-Assistent	43
RECODE-Kommando	114	Statistisches Bundesamt	6
Regressionsanalyse	161, 164	StatTransfer	72
Repräsentativität	46	Statuszeile	39
Repräsentativität der Stichprobe	206	Stichprobe	8
Residualkategorien	29	Stichprobenmodell	146, 215
Rohdatendatei	64, 111	Stichprobenumfang	13
Rolle einer Variablen	54	Streudiagramm	186
Rückgängig-Befehl		String-Variablen	28
im Datenfenster	67	Strukturierung	23
S		Subkommando	256
SamplePower	13, 37	Suchen	
SAV-Dateien	62	Daten	90
SAVE-Kommando	140	Symbolleisten	39
Schätzmethoden	1	Syntaxdiagramm	254
Schiefe	85	Syntaxfenster	102, 108, 252
Schreibschutz	112	Kommandos ausführen	105
SEED	129	Syntax-Regeln	109
Sekundäranalyse	5	SYSMIS	29, 65, 66, 91, 130
SELECT IF	124	Systemdefiniert fehlend	29
Separierte Daten	245	System-Missing	29, 117
Shapiro-Wilk - Test	157	T	
Shapiro-Wilk - Test	158	Tabellenvorlagen	178
Skalenniveau	7, 28, 54	Teilausgabe	79
SOEP	6	Teilnehmerliste	73
Sortierung bei Variablenlisten	250	Teleform	47
Spaltenbreite	177	TeleForm	35
Spaltenformat	52	Testproblem	
Spannweite	85	zweiseitiges	151
Speichern		Teststärke	150, 164
Arbeitsdatei	61	t-Test zum Regressionskoeffizienten	164
SPSS		Teststatistik	146, 217
Kommandosprache	236	Text Analytics for Surveys	27, 37
Mietlizenzen	38	Textdatendateien	238
SPSS-		Textimport-Assistent	238
Prozessor	101	TO	127
		TO-Schlüsselwort	257

Transformations-Kommandos	255	Variablenlabel	52
Transformationsprogramm	64, 102, 111, 139	Variablenlisten	249, 257
Transformieren		Variablennamen	23, 32
Berechnen	124	Variablentypen	27, 51
Umkodieren	114	Varianz	85
Zählen	137	Varianzhomogenität	154
t-Test		Varlist	257
für eine Stichprobe	131	Verfälschter Test	151
für verbundene Stichproben	12, 148	Vergleich	135
Tukey-Angelpunkte	155	Vergleichsoperatoren	135
t-Verteilung	147	Verschieben	
U		Fall	67
Überschreitungswahrscheinlichkeit	148	Variable	58
Umkodieren	114	von Kategorien	176
Umlaute		Vertrauensintervall	2, 91
in Variablennamen	32	Viewer	39, 78, 170
Unabhängigkeit	146	Visualization Designer	37, 190
von Residuen	6	Visuelles Klassieren	120
Unabhängigkeitshypothese	214	Vorlagen	
Unipark	46	Graphiken	198
Unkorreliertheit der Residuen	154	Vorzeichentest	159, 167
Untersuchungsdesign	7	W	
Untersuchungsplanung	6, 10	Wahrheitstafeln	136
V		Wahrheitswert	135
VALUE LABELS – Kommando	142	Wertelabels	52, 61, 65
Variable	22	Z	
einfügen	57	Zählen von Werten	137
löschen	58	Zelleneigenschaften	177
verschieben	58	Zufällige Teilstichprobe ziehen	203
Variablen		Zufallszahlengenerator	129
abgeleitete	24	Zweiseitiges Testproblem	151
Variablenattribute	51	Zwischenablage	80
Variablendefinition	50		