

### Test-Retest-Studie - Methodenstudie des ALLBUS: Abschlußbericht

Zeifang, Klaus

Veröffentlichungsversion / Published Version  
Abschlussbericht / final report

Zur Verfügung gestellt in Kooperation mit / provided in cooperation with:  
GESIS - Leibniz-Institut für Sozialwissenschaften

#### Empfohlene Zitierung / Suggested Citation:

Zeifang, K. (1987). *Test-Retest-Studie - Methodenstudie des ALLBUS: Abschlußbericht*. (ZUMA-Arbeitsbericht, 1987/02). Mannheim: Zentrum für Umfragen, Methoden und Analysen -ZUMA-. <https://nbn-resolving.org/urn:nbn:de:0168-ssoar-66416>

#### Nutzungsbedingungen:

Dieser Text wird unter einer Deposit-Lizenz (Keine Weiterverbreitung - keine Bearbeitung) zur Verfügung gestellt. Gewährt wird ein nicht exklusives, nicht übertragbares, persönliches und beschränktes Recht auf Nutzung dieses Dokuments. Dieses Dokument ist ausschließlich für den persönlichen, nicht-kommerziellen Gebrauch bestimmt. Auf sämtlichen Kopien dieses Dokuments müssen alle Urheberrechtshinweise und sonstigen Hinweise auf gesetzlichen Schutz beibehalten werden. Sie dürfen dieses Dokument nicht in irgendeiner Weise abändern, noch dürfen Sie dieses Dokument für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, aufführen, vertreiben oder anderweitig nutzen.

Mit der Verwendung dieses Dokuments erkennen Sie die Nutzungsbedingungen an.

#### Terms of use:

This document is made available under Deposit Licence (No Redistribution - no modifications). We grant a non-exclusive, non-transferable, individual and limited right to using this document. This document is solely intended for your personal, non-commercial use. All of the copies of this documents must retain all copyright information and other information regarding legal protection. You are not allowed to alter this document in any way, to copy it for public or commercial purposes, to exhibit the document in public, to perform, distribute or otherwise use the document in public.

By using this particular document, you accept the above-stated conditions of use.

Test-Retest-Studie -  
Methodenstudie des ALLBUS  
-Abschlußbericht-

Klaus Zeifang

Zuma-Arbeitsbericht Nr. 87/02

Februar 1987



### VORBEMERKUNG

Im Rahmen der Allgemeinen Bevölkerungsumfrage der Sozialwissenschaften (ALLBUS) wurden zu jeder der bisher durchgeführten Repräsentativerhebungen begleitende Studien zur methodischen Grundlagenforschung durchgeführt. Im ALLBUS 1980 war durch ein umfangreiches Eigeninterview der Interviewer die Frage nach Interviewereinflüssen im mündlichen Interview untersucht worden, im ALLBUS 1982 die Frage nach der internationalen Vergleichbarkeit von Einstellungsskalen.

Die Deutsche Forschungsgemeinschaft (DFG) hat mit der Bewilligung des ALLBUS 1984 (Aktenzeichen Mu 666/1-6, Kennwort: ALLBUS 1984, beantragt am 17. Dezember 1982, bewilligt am 1. Juni 1983) auch der Durchführung der Methodenstudie zum ALLBUS 1984, der Test-Retest-Studie, zugestimmt.

Der Forschungsbericht zur ALLBUS-Haupterhebung 1984 wurde der DFG als Anlage A1 des Antrags auf Gewährung einer Sachbeihilfe zum ALLBUS 1986 bereits im März 1985 vorgelegt. Gegenstand des vorliegenden Abschlußberichts sind ausschließlich die Forschungsarbeiten im Zusammenhang mit der Test-Retest-Studie.

Im ersten Teil dieses Berichts soll zunächst in Form eines konventionellen Methodenberichts die technische Durchführung der Studie dargestellt werden. Beginnend mit einem kurzen Rückblick auf die Konzeption und Begründung der Studie wird die Vorbereitung sowie das überarbeitete Design erläutert und anschließend ihre Realisierung und das zur Feldkontrolle angewandte Verfahren beschrieben.

Der zweite Abschnitt beschäftigt sich mit der Qualität der Stichprobe und der Antwortstabilität über die Wellen. In einem ersten Schritt wird ein systematischer Querschnittsvergleich zwischen den Befragten der Hauptstudie und denjenigen Befragten, die später auch an beiden Nachbefragungen teilgenommen haben, vorgenommen. Verglichen werden ihre demographische Struktur und ihre Antworten auf Einstellungsfragen. Der nächste Schritt beinhaltet den Vergleich des Antwortverhaltens der Befragten der Test-Retest-Stichprobe



über alle drei Wellen. Während es also im ersten Schritt um die Frage der Stichprobenqualität geht, bezieht sich der zweite Schritt auf die Stabilität des Antwortverhaltens über die Zeit.

### 1. Die-Test-Retest-Studie zum ALLBUS 1984 - Konzeption, Realisierung und Qualität der Stichprobe

Alle Überlegungen zur Konzeption und Durchführung der Test-Retest-Studie sind ausgegangen vom Zeitreihencharakter der ALLBUS-Daten. Will man sich, insbesondere im Rahmen komplexer Analysemodelle, versichern, daß es sich bei gemessenen Veränderungen über die Zeit tatsächlich um Wandel und nicht nur um methodische Artefakte handelt, sind Angaben über die methodische Qualität der Meßinstrumente unabdingbar. Als Indikator für die Stabilität von Meßinstrumenten über die Zeit eignet sich die Test-Retest-Reliabilität.

#### 1.1 Konzeption und Begründung der Test-Retest-Studie

Reliabilität von Meßinstrumenten gilt, neben Validität, als zentrale Voraussetzung für den Test von Hypothesen. Die wichtigsten statistischen Grundlagen zur Messung von Reliabilität wurden in der psychologischen Testtheorie entwickelt und auch von soziologischer Seite übernommen (Heise und Bohrnstedt 1970: 104-129). Trotz der allgemein anerkannten Bedeutung von Reliabilitätsmessungen werden in vielen Arbeiten der empirischen Sozialforschung Reliabilitäten häufig nicht berechnet oder zumindest nicht publiziert (Porst und Schmidt 1982: 9).

Das aus der klassischen Testtheorie (Lord und Novick 1968) bekannte Konzept der Reliabilität setzt sich a) mit der Stabilität eines Meßinstruments und/oder b) mit der internen Konsistenz eines Sets von Items auseinander, von denen anzunehmen ist, daß sie ein gemeinsames latentes Konstrukt messen. Reliabilität ist definiert als die quadrierte Korrelation zwischen gemessenen und "wahren" Werten von Variablen bzw. als Maß für das Verhältnis der Varianz der wahren Werte zur Varianz der beobachteten Werte. Mit anderen Worten: Ein hoher Reliabilitätskoeffizient ist ein Indikator für eine hohe

Interkorrelation zwischen dem empirischen Wert einer Variablen und ihrem wahren Wert (Lord und Novick 1968).

Die Messung der Test-Retest-Reliabilität erweist sich aus mehreren Gründen als schwierig:

1. Veränderungen gemessener Werte über die Zeit können Folge von Meßfehlern, aber auch Folge tatsächlichen Wandels sein, oder von beidem zusammen.
2. Veränderungen gemessener Werte können Folge unterschiedlicher kontextueller Bedingungen bei den Interviews der unterschiedlichen Befragungswellen sein (z.B. aufgrund der unterschiedlichen Anwesenheit weiterer Personen beim Interview).
3. Konstanz gemessener Werte kann dadurch entstehen, daß beim Befragten ein Lern- oder Erinnerungseffekt auftritt (der Befragte könnte sich z.B. bewußt bemühen, die gleichen Antworten zu geben wie beim ersten Interview, auch wenn sich seine tatsächliche Einstellung zu einem bestimmten Problem seit damals verändert hat).
4. Veränderungen gemessener Werte können einfach dadurch entstanden sein, daß sich der Befragte nach dem ersten Interview mit dem Gegenstand des Interviews intensiver befaßt hat und erst dadurch - also mithin als Folge der Erstbefragung - eine Meinungs- oder Einstellungsänderung aufgetreten ist (vgl. Campbell und Stanley 1966).

Da im ALLBUS als einer auf Replikation basierenden Studie bestimmte Erhebungsinstrumente regelmäßig eingesetzt werden, erschien es unbedingt notwendig, Informationen über die Test-Retest-Reliabilität zumindest dieser Standardinstrumente zu erhalten. Neben diesem eher forschungspragmatischen Argument gibt es mindestens zwei systematische Argumente, die die Durchführung der Test-Retest-Studie im Zusammenhang mit dem ALLBUS als einer Datenbasis für Zeitreihenanalysen nicht nur sinnvoll, sondern unabdingbar erscheinen ließen.

So kann, erstens, mit Hilfe dieser Panel-Studie ermittelt werden, wie konsistent Befragungspersonen die gleichen Fragen beantworten, wenn sie innerhalb relativ kurzer Zeit mehrmals mit ihnen konfrontiert werden: die Ergebnisse der Test-Retest-Studie ermöglichen Aussagen über kurzfristige

Veränderungen oder über die Stabilität von Merkmalen und Einstellungen auf Individualebene. Unseres Wissens nach ist diese Fragestellung in einer allgemeinen Bevölkerungsumfrage bisher nicht untersucht worden.

Da Daten zu drei Erhebungszeitpunkten vorliegen, kann, zweitens, durch die Anwendung von Strukturgleichungsmodellen zwischen wahren Wandel und Meßfehlern differenziert werden (vgl. Heise 1969, Wiley und Wiley 1970).

## 1.2 Design der Test-Retest-Studie

Die Entwicklung des Designs für die Test-Retest-Studie erwies sich aus verschiedenen Gründen als ein recht schwieriges Unterfangen, dessen Ablauf im einzelnen hier nicht weiter beschrieben werden soll. In den folgenden Abschnitten sollen deshalb nur die Ergebnisse der Diskussionen über die Ausgestaltung der Studie aufgeführt werden. Als Einzelpunkte des Studien-Designs werden die Vorstellungen über das Feld – insbesondere über die Zahl der Erhebungen und die Zeitabstände zwischen den Erhebungen – der Stichprobenplan und die Stichprobengröße sowie das Erhebungsinstrument erläutert werden.

### 1.2.1 Vorstellungen über das Feld

In der einschlägigen Literatur besteht Übereinstimmung, daß mindestens drei Erhebungszeitpunkte vorliegen müssen, um die die Test-Retest-Reliabilität bestimmenden Einflußgrößen hinreichend identifizieren zu können (vgl. Heise 1969, Arminger 1976, Kessler und Greenberg 1981). Nur beim Vorliegen dreier Meßzeitpunkte<sup>1)</sup> kann eine Trennung von Zusammenhängen zwischen latenten Variablen und Meßfehlerkorrelationen erfolgen (vgl. Jöreskog und Sörbom 1977). Darüberhinaus ergeben sich weitere Möglichkeiten der systematischen Exploration von Effekten in Strukturgleichungsmodellen.

Da die Haupterhebung des ALLBUS 1984 als erste Welle des Panels angenommen wurde, waren demzufolge also zwei Nachbefragungen erforderlich. Im folgenden

bezeichnen wir die Haupterhebung als erste Welle, die erste Nachbefragung als zweite Welle und die zweite Nachbefragung als dritte Welle.

Über die Abstände zwischen den Erhebungen bei einem Panel liegen keine allgemein verbindlichen Aussagen vor; sie hängen im wesentlichen von den Zielen der jeweiligen Untersuchung ab. Für die Test-Retest-Studie wurde eine sowohl theoretisch fundierte als auch pragmatische Regelung gefunden. Die Abstände zwischen den Wellen sollten relativ kurz sein, um das Ausmaß tatsächlicher Veränderungen zu minimieren. Allerdings sollten die Zeitabstände auch nicht zu kurz sein, weil das Antwortverhalten sonst zu stark von Erinnerungs- oder Lerneffekten der Befragten überlagert sein könnte. Da die gesamte Feldzeit des ALLBUS 1984 ohnehin nicht unangemessen ausgedehnt werden konnte, wurde schließlich entschieden, daß jede Person der Stichprobe jeweils nach exakt vier Wochen zum erstenmal, nach exakt weiteren vier Wochen zum zweitenmal nachbefragt werden sollte, wobei eine geringe Varianz im Falle kurzfristigen Nicht-Erreichens einkalkuliert wurde.

#### 1.2.2 Stichprobenplan und Stichprobengröße

Das Stichprobenverfahren sollte so angelegt sein, daß als Ergebnis der dritten Panel-Welle noch mindestens 150 vollständig realisierte Interviews vorliegen sollten. Diese Zahl, die später auch tatsächlich erreicht werden konnte, hat sich alles in allem – insbesondere für die Analyse von Subgruppen – immer noch als relativ niedrig erwiesen, konnte allerdings im Rahmen einer realistischen Kostenkalkulation für die Gesamtstudie nicht höher angesetzt werden.

Die im Antrag definierte Grundgesamtheit der Befragten für die zweite Welle mußte aus Kostengründen neu definiert werden. Nicht mehr alle Befragten, für die in der Hauptstudie ein vollständiges Interview realisiert wurde (vgl. Antrag: 28), sollten zur Grundgesamtheit gehören, sondern nur noch die Befragten eines der drei in der Hauptstudie eingesetzten Stichprobennetze<sup>2)</sup>. Ausgesucht wurde das Netz, im dem in der Hauptstudie acht Brutto-Adressen als Kontaktadressen bearbeitet werden sollten (in den beiden anderen Netzen

sollten nur je 7 Adressen bearbeitet werden). Zum Einsatz sollten alle 210 sample points dieses Netzes kommen.

In jedem dieser 210 sample points sollte von allen Befragten der Haupterhebung die Bereitschaft zur Teilnahme an zwei Wiederholungsbefragungen erbeten werden. Je zwei der acht Adressen jedes der 210 sample points sollten für die Nacherhebungen ausgewählt werden. Die Interviewer sollten zum Zeitpunkt der Haupterhebung selbst nicht wissen, daß es dort definitiv zu Nachbefragungen kommen sollte.

Die Auswahl dieser zwei Adressen sollte nach folgendem Schema durchgeführt werden:

<u>Sample point Nr.</u>	<u>001</u>	<u>002</u>	<u>003</u>	<u>004</u>	<u>005</u>	<u>006</u>	<u>007</u>	<u>008</u>	
Adressen Nr.:	1/5	2/6	3/7	4/8	1/5	2/6	3/7	4/8	u.s.w.

Damit hätte sich ein Brutto-Ansatz von insgesamt 420 Kontaktadressen (210 sample points x 2 Adressen) als Ausgangspunkt für die Test-Retest-Studie ergeben. Bei einer erwarteten Ausschöpfung von 70% für die ALLBUS-Hauptstudie reduzierte sich die Anzahl der Adressen auf 294.

Von diesen 294 sollten sich - so die Schätzung - 235 oder 80% nach dem Interview in der Hauptstudie zur Teilnahme an weiteren Befragungen bereiterklären. Von diesen 235 sollten dann - wiederum geschätzt - ca. 85% tatsächlich in der zweiten Welle teilnehmen; die Zahl der realisierten Interviews nach der zweiten Welle wurde somit auf ca. 200 festgelegt. Wenn - so die weitere Schätzung - von diesen 200 wiederum 75% auch in der dritten Welle teilnahmen, wäre die angestrebte Stichprobengröße von 150 vollständigen Interviews in der dritten Welle realisiert.

### 1.2.3 Das Erhebungsinstrument

Erhebungsinstrument der ersten Welle des Panels war der reguläre Fragebogen zum ALLBUS 1984. Gemäß den datenschutzrechtlichen Bestimmungen enthielt er am Ende eine Erklärung über die Bereitschaft zur Teilnahme an weiteren Befragungen.

Das Instrument, mit dem die Nachbefragungen durchgeführt wurde, war eine auf etwa die Hälfte der Befragungszeit reduzierte Version des Fragebogens der Hauptstudie. Die Fragen, die in der Nachbefragung zum Einsatz kamen, wurden unter verschiedenen Gesichtspunkten ausgewählt. In erster Linie wurden Fragen berücksichtigt, die als Standardinstrumente des ALLBUS-Programms gelten können, also Fragen, die bereits innerhalb von ALLBUS-Umfragen repliziert worden waren. Dabei sollten Fragen unterschiedlichen Skalenniveaus zum Einsatz kommen, und zwar sowohl Fragen aus den inhaltlichen Bereichen als auch demographische Fragen.

### 1.3 Realisierung der Studie

Die angestrebte Stichprobengröße von 150 vollständig realisierten Interviews in der dritten Welle konnte, trotz einer nicht ganz den Erwartungen entsprechenden Teilnahmebereitschaft der Befragten nach der Hauptstudie, letztlich doch realisiert werden. Statt der ursprünglich 235 Personen erklärten sich nach dem ersten Interview nur 210 zur Teilnahme an weiteren Befragungen bereit. Von diesen 210 Personen konnten in der zweiten Welle 181 (oder 86%) befragt werden, in der dritten Welle noch einmal 154 (oder 85% von 181). Anders ausgedrückt: von den 210 Personen, die ursprünglich zur Teilnahme an den Nachbefragungen bereit waren, konnten 154 (73% von 210) tatsächlich dreimal befragt werden (detaillierte Angaben zur Ausschöpfung finden sich in Tabelle A).

Tabelle A<sup>3)</sup>: Erwartete und realisierte Ausschöpfung der Test-Retest-Studie

	Erwartet	Realisiert
a Haushalts-Adressen	420	420
b Teilnehmer an der ersten Befragung (Hauptstudie)	294=70% von a	255=61% von a
c Zur Teilnahme an Nachbefragungen bereit	235=80% von b	210=82% von b
d Teilnehmer der zweiten Welle	200=85% von c	181=86% von c
e Teilnehmer der dritten Welle	150=75% von d	154=85% von d

Ein zentrales Problem jeder Panel-Studie ist die sog. "Sterblichkeit" (Campbell und Stanley 1966), also das Wegfallen von Befragungspersonen über die Zeit. Da es in der Test-Retest-Studie zum ALLBUS 1984 in fast allen Fällen gelungen war, Kontakt zur Zielperson aufzunehmen, können die Gründe für den Ausfall von Befragungspersonen reproduziert werden (s. Tabelle B).

Tabelle B: Ausfallgründe in der Test-Retest-Studie

	Ausfall in der ...					
	2. Welle		3. Welle		Gesamt	
	N	%	N	%	N	%
a) Nichterreichbarkeit	4	13.8	4	14.8	8	14.3
Urlaub, Dienstreisen	6	20.7	8	29.6	14	25.0
b) Krankheit	4	13.8	6	22.2	10	17.9
c) Verweigerungen, Abbrüche	2	6.9	-	-	2	3.6
"Zu persönliche Fragen"	2	6.9	-	-	2	3.6
"Fragegleichheit"	5	17.2	-	-	5	8.9
Kein Interesse	4	13.8	3	11.1	7	12.5
Keine Zeit	2	6.9	4	14.8	6	10.7
Trotz Terminabsprache nicht anzutreffen	-	-	2	7.4	2	3.6
	29	100.0	27	99.9	56	100.1

Aus der Tabelle lassen sich drei Hauptarten von Ausfällen ablesen, nämlich a) Nichterreichbarkeit, b) befragungsunabhängige Auffälle (Krankheit) und c) "reaktive" Ausfälle, die man als mehr oder minder massive Verweigerungen zu interpretieren hat.

Um zu vermeiden, daß die Befragungsergebnisse über die Zeit durch einen Wechsel des Interviewers zwischen den drei Wellen beeinflußt würden, sollten die Nachbefragungen von jeweils dem gleichen Interviewer durchgeführt werden, der auch die Befragung in der ersten Welle ausgeführt hatte. Dies konnte in 130 oder 84% der 154 in allen drei Wellen realisierten Interviews auch erreicht werden. In 23 Fällen waren zwei Interviewer an der Realisierung der drei Interviews beteiligt, in einem Fall drei Interviewer.

Die Interviews der Nachbefragungen wurden in der Zeit zwischen dem 15. April und 8. August 1984 durchgeführt. Ausgehend von den Interviews in der Haupterhebung (Feldzeit: 12. März - 30. Mai 1984) sollte jede Befragungsperson nach exakt vier Wochen zum ersten, nach exakt weiteren vier Wochen zum zweitenmal nachbefragt werden.

Im Laufe der Feldzeit zeigte sich schnell, daß diese Vorgabe zu restriktiv war. Oft konnte - trotz prinzipieller Bereitschaft eines Befragten zur Teilnahme an weiteren Befragungen - kein Termin in der geplanten Erhebungswoche realisiert werden. Um die angestrebte Ausschöpfungsquote erreichen zu können, wurden deshalb die Abstände zwischen den Befragungen frühzeitig neu definiert: nicht mehr die vierte und die achte Woche nach der Befragung in der ersten Welle allein sollten zulässig sein, sondern - allerdings nur als Ausnahme von dieser Regel - eine Zeitspanne von der dritten bis zur fünften und von der siebten bis zur neunten Woche.

Alles in allem konnte aber auch diese weitergefaßte Vorgabe nicht völlig eingehalten werden. Der Abstand zwischen den Befragungen der ersten und zweiten Welle betrug zwar durchschnittlich 32 Tage, zwischen der zweiten und dritten Welle durchschnittlich 28 Tage, doch wurden 24% der Interviews in der zweiten Welle mehr als 5 Wochen nach der Befragung in der ersten Welle realisiert, 13% der Interviews in der dritten Welle mehr als fünf Wochen



nach der Befragung in der zweiten Welle. Im einzelnen ergab sich das folgende Bild:

Tabelle C: Zeitabstände zwischen den Befragungen

	Abstand zwischen der ...			
	1. und der 2. Welle		2. und der 3. Welle	
	N	%	N	%
weniger als 25 Tage	3	1.9	38	24.7
25 Tage	1	0.6	6	3.9
26 Tage	5	3.2	10	6.5
27 Tage	1	0.6	17	11.0
28 Tage	20	13.0	16	10.4
29 Tage	18	11.7	11	7.1
30 Tage	19	12.3	10	6.5
31 Tage	11	7.1	10	6.5
32 Tage	27	17.5	5	3.2
33 Tage	7	4.5	6	3.9
34 Tage	5	3.2	5	3.2
35 Tage und mehr	37	24.0	20	13.0
	154	99.6	154	99.9

#### 1.4 Feldkontrolle

Bei der ALLBUS-Hauptstudie wurden routinemäßig 50% der realisierten Interviews feldkontrolliert. Die zumeist in postalischer Form durchgeführten Feldkontrollen würden jedoch angesichts der besonderen Wichtigkeit eines ordnungsgemäßen Feldverlaufs bei der Datenerhebung der Test-Retest-Studie als nicht ausreichend angesehen.

In Abstimmung mit dem Datenerhebungsinstitut GETAS (Gesellschaft für angewandte Sozialpsychologie mbH, Bremen) wurde deshalb beschlossen, daß die Mitarbeiter der ALLBUS-Projektgruppe nach Abschluß der Feldzeit der letzten Welle das gesamte Feld der Restest-Studie nochmals telefonisch kontrollieren sollten. Diese Feldkontrolle sollte insgesamt drei Wochen dauern. Alle Interviews, bei denen Zweifel an der Korrektheit des Zustandekommens nicht ausgeräumt werden könnten, sollten aus der weiteren Bearbeitung ausgeschlossen werden.

Um die Geduld der Befragten nach in der Regel über zweistündiger Befragungszeit für alle drei Wellen nicht mehr als unbedingt nötig zu strapazieren, sollte die telefonische Nachfrage relativ kurz sein und neben den Fragen zum Zustandekommen des Interviews nur wenige statistische Kennwerte erfassen.

Den Befragten sollte zunächst der Zweck des telefonischen Kurzinterviews erläutert werden (Kontrolle der Interviewer). Die Gesprächspartner sollten dann die Anzahl der Interviews und den Befragungszeitraum angeben, in dem die Interviews durchgeführt worden waren. Abschließend wurden sie um die Nennung von Familienstand, Konfession und Geburtsdatum gebeten. Die Projektmitarbeiter handelten unter der Vorgabe, daß sie alle diese Angaben nur von den in der Test-Retest-Studie befragten Personen selbst erhalten sollten.

Die telefonische Feldkontrolle wurde von den ALLBUS-Projektmitarbeitern zwischen dem 17. August und dem 21. September 1984 durchgeführt. Die Feldzeit der Kontrollen mußte wegen der zum Teil schwierigen Erreichbarkeit vieler Befragter (vor allem wegen Urlaubs) weiter ausgedehnt werden als ursprünglich intendiert.

Von den 154 Personen, die in allen drei Wellen befragt worden waren, konnten 135 (87,7%) telefonisch erreicht werden. Die restlichen 19 Personen hatten entweder keinen Telefonanschluß bzw. der Telefonanschluß konnte nicht ermittelt werden.

Generell läßt sich zunächst festhalten, daß die gestellten Fragen von den meisten der 135 kontaktierten Personen bereitwillig beantwortet wurden. Während wir auf die drei Fragen zu soziodemographischen Merkmalen von allen Gesprächspartnern Antworten erhielten, hatten bei den Fragen zur Anzahl der Interviews und zum Gesamtzeitraum der Befragungen doch viele Befragte Schwierigkeiten, sich zu erinnern. Zwar konnte die Anzahl der Interviews von immerhin noch ca. 75% der Befragten nach einigem Nachdenken angegeben werden, doch waren nur noch die wenigsten Personen in der Lage, den ungefähren Befragungszeitraum auf die entsprechenden Monate einzugrenzen. Wesentlich

häufiger antworteten unsere Gesprächspartner, daß die drei Interviews ungefähr in Abständen von je einem Monat stattgefunden hätten.

Als erstes Ergebnis der telefonischen Feldkontrolle ordneten wir die Interviews drei verschiedenen Kategorien zu: Korrekt durchgeführte Interviews, Interviews mit leichten und Interviews mit stärkeren Zweifeln an der korrekten Durchführung.

Als Interviews, bei denen wir zunächst leichtere Zweifel hatten, stufen wir solche ein, bei denen beispielsweise der Gesprächspartner nicht mehr sicher angeben konnte, ob zwei oder drei Interviews durchgeführt worden waren, oder wenn die Person in den letzten Monaten mehrere Interviews gegeben hatte und sich an einzelne davon nicht mehr genau erinnern konnte.

Als Interviews mit stärkeren Zweifeln an der korrekten Durchführung klassifizierten wir solche, bei denen der Gesprächspartner angab, daß er kein oder "ganz sicher" nur ein oder zwei Interviews gegeben oder die Befragungsperson innerhalb der drei Wellen gewechselt habe (z.B. sei einmal der Ehemann, dann seine Frau befragt worden).

Als Ergebnis der telefonischen Feldkontrolle konnten wir schließlich 91 Interviews (67.4% von 135) als korrekt durchgeführt einstufen, bei 16 Interviews (11.9%) hatten wir leichtere Zweifel, bei 28 Interviews (20.7%) stärkere Zweifel an ihrer korrekten Durchführung.

Die Ergebnisse der telefonischen Feldkontrolle sollten allerdings mit erheblicher Vorsicht interpretiert werden. So hatten – wie bereits erwähnt – doch viele Personen erhebliche Erinnerungsprobleme. Man muß sich fragen, ob die telefonischen Befragungen wirklich einen "harten" Test der Verlässlichkeit bei der Durchführung der Interviews darstellen. Diese Skepsis wird durch die Ergebnisse zweier weiterer Kontrollen noch verstärkt.

Die ALLBUS-Projektmitarbeiter führten für die 44 zweifelhaften Fälle Konsistenzprüfungen zwischen den telefonischen Angaben der Personen und den Angaben aus den face-to-face-Interviews durch. Zum Beispiel wurden die demographischen Variablen derjenigen Personen über alle drei Wellen hinweg

verglichen, die am Telefon angegeben hatten, daß die Befragungsperson gewechselt habe. Die telefonischen Angaben wurden dabei in keinem Falle durch die Angaben in den mündlichen Interviews bestätigt.

Schließlich wurden die 44 zweifelhaften Fälle nochmals vom Datenerhebungsinstitut selbst überprüft. Nach Aussagen des dortigen Studienleiters konnten sich in keinem Fall Anzeichen auf eine nicht-korrekte Durchführung der Interviews erhärten lassen.

Die endgültige Klärung, ob eines oder mehrere dieser von uns zunächst als zweifelhaft eingestuft Interviews tatsächlich nicht korrekt zustande gekommen ist, war somit mit letzter Sicherheit nicht möglich. Die Projektgruppe entschloß sich deshalb, alle 154 Fälle als korrekt einzustufen und in die Analysen einzubeziehen.

## 2. Qualität der Stichprobe und die Stabilität der Antworten

In diesem Kapitel untersuchen wir die empirisch nachprüfbare Qualität der Daten der Test-Retest-Studie. Im ersten Teil dieses Kapitels werden wir die Befragten der Hauptstudie, die nicht an der Restest-Studie teilgenommen haben, denjenigen Befragten gegenüberstellen, die später auch an den beiden Nachbefragungen teilgenommen haben. Verglichen werden ihre demographische Struktur und ihre Antworten auf ausgewählte Einstellungsfragen. Im zweiten Teil werden wir das Antwortverhalten der Befragten der Test-Retest-Stichprobe analysieren. Während es dabei um die Stabilität des Antwortverhaltens über die Zeit geht, wird im ersten Teil nach der Qualität der Stichprobe gefragt.

### 2.1 Vergleich der Panel-Stichprobe mit der Stichprobe des ALLBUS 1984

Um zu prüfen, inwieweit die Test-Retest-Stichprobe zumindest näherungsweise ein Abbild der Hauptstudie widerspiegelt, wurden für eine große Anzahl ausgewählter Variablen die Häufigkeitsverteilungen der

Hauptstudie (bezogen auf  $3004 - 154 = 2850$  Befragte) mit denen der Test-Retest-Teilstichprobe verglichen. Mit Hilfe des  $\text{Chi}^2$ -Tests wurde dann geprüft, ob die Verteilungen für die entsprechenden Variablen signifikant voneinander abwichen.

Bei dem Vergleich der Häufigkeitsverteilungen berücksichtigten wir vor allem die wichtigsten sozio-demographischen Variablen, die durch weitere objektive Merkmale wie die "frühere berufliche Stellung" und die "berufliche Stellung des Vaters" ergänzt wurden.

Neben diesen, für einen Vergleich der ALLBUS-Hauptstudie und der Test-Retest-Stichprobe zentralen Merkmalen haben wir noch eine große Anzahl von Einstellungsvariablen zu verschiedenen Themenbereichen nach der gleichen Vorgehensweise analysiert. Unser besonderes Interesse galt dabei den Fragen zu den Bereichen Wohlfahrtsstaat, Ungleichheit, Gastarbeitern und Politik.

Für die jeweiligen Itembatterien zu diesen Themenbereichen haben wir darüberhinaus die Kovarianzen berechnet. Wir haben dann auch hier die jeweiligen Kovarianzmatrizen der Befragten der Test-Retest-Studie mit den restlichen Befragten der Hauptstudie verglichen. Ein Vergleich der Kovarianzmatrizen stellt einen strengeren Test der Datenqualität der Test-Retest-Studie dar als der bloße Vergleich der Randverteilungen. Sind nämlich auch die bivariaten Verteilungen zwischen den Stichproben ähnlich, ist dies ein weiterer Beleg für die These, daß die Test-Retest-Stichprobe ein verkleinertes Spiegelbild der ALLBUS-Stichprobe ist, ein Ergebnis, das wegen möglicher Zufälligkeiten im Antwortverhalten aus dem Vergleich der Randverteilungen alleine nicht unbedingt zu erzielen ist.

### 2.1.1 Vergleich der Häufigkeitsverteilungen

Der Vergleich der Randverteilungen bei den demographischen Variablen<sup>4)</sup> zeigt keine signifikanten Unterschiede zwischen der Test-Retest-Stichprobe und der Stichprobe der Hauptstudie. Einzige Ausnahme der analysierten demographischen Variablen ist das Alter des Befragten mit einem  $\text{Chi}_5^2$ -Wert

von 24.43 bei einem Signifikanzniveau von  $p < .000$ . Allerdings hat dieser hohe  $\text{Chi}^2$ -Wert seine Ursache in der Berechnungsformel dieses Maßes<sup>5)</sup>. Bei einer anderen Zusammenfassung treten keine signifikanten Unterschiede zwischen den Verteilungen auf.

Die - allerdings noch nicht signifikanten - Abweichungen beim Einkommen ( $\text{Chi}_{10}^2 = 16.29$ ,  $p < .092$ ) sind gleichermaßen auf die Kategorisierung zurückzuführen. Auch hier würde der  $\text{Chi}^2$ -Wert bei einer anderen Zusammenfassung der Kategorien (z.B. zu insgesamt 5 neuen Kategorien) ebenfalls dramatisch sinken, da sich dadurch die Abweichungen der Prozentwerte insbesondere der unteren Kategorien erheblich verringern würden.

Zusammenfassend können wir festhalten, daß sich bei keiner sozio-demographischen Variablen signifikante Unterschiede zwischen den Häufigkeitsverteilungen der Stichprobe des ALLBUS 1984 und der Retest-Stichprobe zeigen, d.h. die Retest-Stichprobe bei den demographischen Variablen in der Tat ein verkleinertes Abbild der ALLBUS-Hauptstudie darstellt.

Neben den demographischen Variablen wurden - auf die gleiche Weise - ca. 50 Einstellungsitems überprüft. Der Vergleich dieser Items zwischen der Test-Retest-Stichprobe und den restlichen Befragten der Hauptstudie führte nur in einem Fall (Parteienthermometer für die DKP) zu einem signifikanten Unterschied<sup>6)</sup> zwischen den beiden Stichproben<sup>7)</sup>.

Obgleich gerade bei den Einstellungsvariablen in stärkerem Maße als bei den demographischen Variablen Unterschiede in den Häufigkeitsverteilungen zu erwarten waren, ist es doch außerordentlich bemerkenswert, daß auch bei diesen Variablen keine signifikanten Verzerrungen der Randverteilungen aufgetreten sind.

### 2.1.2 Vergleich der Kovarianzen ausgewählter Einstellungssitems

Obwohl bereits der Vergleich der univariaten Verteilungen der Einstellungssitems zwischen ALLBUS-Hauptstudie und Test-Retest-Studie ein durchgängig positives Ergebnis im Sinne unserer Erwartungen erbrachte, hielten wir es dennoch für erforderlich, auch bivariate Verteilungen (Kovarianzen) zwischen ausgewählten Items bzw. innerhalb bestimmter Itembatterien zu berechnen und zu vergleichen. Dieses Vorgehen ist sicherlich aussagekräftiger als der bloße Vergleich der Randverteilungen.

Beim Vergleich der Kovarianzen haben wir uns beschränkt auf die Itembatterien "Einstellungen zum Wohlfahrtsstaat", "Einstellungen zu sozialer Ungleichheit", "Einstellungen zu Gastarbeitern" sowie den Einstellungen zu politischen Parteien (Parteienthermometer). Wenn die Test-Retest-Studie in der Tat ein Spiegelbild der ALLBUS-Hauptstudie sein soll, müßten auch die Kovarianzen der Items innerhalb dieser Einstellungsbatterien gleich oder zumindest sehr ähnlich sein.

Als Indikator für die Übereinstimmung zwischen den Kovarianzen dient auch hier der  $\chi^2$ -Test. Eine Übersicht über die Ergebnisse vermittelt Tabelle D<sup>8)</sup>:

Tabelle D: Vergleich der Kovarianzmatrizen der Test-Retest-Studie und der Hauptstudie ALLBUS 1984

	$\chi^2$	df	p
Einstellungen zum Wohlfahrtsstaat	37.05	36	.420
Einstellungen zu sozialer Ungleichheit	27.08	36	.858
Einstellungen zu Gastarbeitern	10.29	10	.416
Einstellungen zu politischen Parteien	40.64	28	.058

Aus der Tabelle ist zu ersehen, daß die Kovarianz-Strukturen der ALLBUS-Hauptstudie und der Test-Retest-Studie sehr ähnlich sind<sup>9)</sup>. Dies bestätigt die Ergebnisse der Vergleiche univariater Verteilungen und führt uns

letztlich zu dem Schluß, daß die Test-Retest-Stichprobe in der Tat ein verkleinertes Abbild der Stichprobe der ALLBUS-Hauptstudie darstellt.

## 2.2 Stabilität von Umfragen - Vergleich ausgewählter Variablen

In den folgenden Abschnitten sollen die Stabilitäten der Antworten auf die in der Test-Retest-Studie verwandten Variablen auf deskriptiver Ebene untersucht werden. Während im folgenden Kapitel die Veränderungen zwischen den einzelnen Wellen und über alle drei Wellen für die demographischen Variablen diskutiert werden, wird in einem weiteren Kapitel derselbe Sachverhalt für die Einstellungsvariablen analysiert werden. Die explizite Darstellung dieser Veränderungen ist u.a. für zukünftige komplexe Analysen unbedingte Vorbedingung: erhebliche Antwortinstabilitäten bei der Beantwortung einzelner Fragen über die jeweiligen Wellen werden die Aufstellung der Modelle mit multiplen Indikatoren beeinflussen wie auch manche ihrer Ergebnisse durch Rekurs auf den Dateninput eine plausible Erklärung erfahren werden.

Die für die Diskussion der Antwortstabilitäten zugrundegelegte Tabelle 5 des Arbeitsberichts ist sowohl für die demographischen als auch die Einstellungsvariablen in drei Teile untergliedert: Teil A enthält jeweils die Ergebnisse für die nominalskalierten Variablen, Teil B die Ergebnisse für die ordinalskalierten Variablen und in Teil C sind die entsprechenden Werte für die intervallskalierten Variablen aufgeführt. Schließlich werden in Tabelle 6 die nach der Vorgehensweise von Heise (1969) geschätzten Reliabilitäten und Stabilitäten für die intervallskalierten Variablen ausgewiesen.

Da nach unserem Wissen bisher noch keine Methode existiert um auch bei kategorialen Variablen Unzuverlässigkeit von wahren Wandel zu trennen, können für diese Variablen aus den Teilen A und B der Tabelle 5 keine entsprechenden Werte errechnet werden. Um jedoch auch die Stabilitäten dieser Variablen zu prüfen, haben wir jeweils die stabilen Antworten über zwei bzw. drei Wellen ausgewiesen und die entsprechenden Assoziationsmaße (Cramer's V für den Teil A sowie Tau B für Teil B) berechnet.<sup>10)</sup>



### 2.2.1 Demographische Variablen

Bei demographischen Variablen kommt der Antwortstabilität aus zwei Gründen besondere Bedeutung zu: Zum einen dienen sie in vielen Analysen von Umfragedaten allgemein als unabhängige Variablen, zum anderen sind die Ergebnisse unserer Analysen wichtig für die Weiterentwicklung standardisierter Instrumente zur Messung soziodemographischer Hintergrundmerkmale in Umfragen.

Bei Betrachtung der kategorialen Variablen über alle drei Wellen zeigen sich bei den prozentualen Antwortstabilitäten beim Geschlecht und beim Familienstand mit 99,4%<sup>11)</sup> bzw. 98,1% Übereinstimmung äußerst befriedigende Stabilitätswerte.

Zufriedenstellende Antwortstabilitäten erhalten wir auch bei den Fragen nach dem allgemeinbildenden Schulabschluß (89,3%) und der Konfessionszugehörigkeit des Befragten (89,0%) sowie dem Schulabschluß des Vaters (89,6%).

Als Ursache für die Veränderungen beim Schulabschluß des Befragten vermuten wir, daß nicht immer der höchste Schulabschluß angegeben wurde, daß ältere Befragte Schwierigkeiten hatten, ihren Schulabschluß in die Antwortkategorien einzuordnen (anderer Name des Abschlusses), oder daß von einigen Befragten der Schulabschluß – insbesondere in der ersten Welle – zu hoch angegeben wurde.

Bei den Befragten, die wechselnde Angaben über ihre Konfessionszugehörigkeit machen nehmen wir an, daß Personen, die aus der Kirche ausgetreten sind bzw. konvertierten in einer Welle die jetzige bzw. keine Konfession genannt und in einer anderen Welle ihre ursprüngliche Konfession angegeben haben.

Die auf den ersten Blick überraschend hohen Werte beim Schulabschluß des Vaters resultieren daher, daß fast 80% der Väter einen Volks- bzw. Hauptschulabschluß haben und somit keine großen Klassifikationsleistungen vom Befragten gefordert waren.

Die Stabilitäten der weiteren ausgewählten sozio-demographischen Variablen sind weniger zufriedenstellend. Variablen, deren Antwortstabilitäten über alle drei Wellen aber als noch akzeptabel bezeichnet werden können, sind "derzeitige berufliche Erwerbstätigkeit" (81,2%), "Überwiegender Lebensunterhalt" (78,4%), "derzeitige berufliche Stellung" (73,0%) und "beruflicher Ausbildungsabschluß" (72,0%). Warum sind diese Stabilitäten eigentlich niedriger als erwartet?

Da alle vier Items über relativ viele Antwortkategorien (zwischen 8 und 32 Kategorien) verfügen, ist die Wahrscheinlichkeit perfekter Antwortübereinstimmung über alle drei Wellen von vornherein nicht sehr hoch. Daneben dürften bei den Fragen nach dem letzten beruflichen Ausbildungsabschluß, der derzeitigen Erwerbstätigkeit und dem überwiegenden Lebensunterhalt diejenigen Befragten Schwierigkeiten haben, sich immer in die gleiche Antwortkategorie einzuordnen, die mehrere Ausbildungsabschlüsse haben, verschiedene Erwerbstätigkeiten ausüben und/oder ihren Lebensunterhalt mit mehreren Einkommensarten bestreiten.

Trotz der relativ niedrigen Stabilitäten über alle drei Wellen sollte man allerdings nicht unberücksichtigt lassen, daß die prozentualen Übereinstimmungen beim Vergleich der einzelnen Wellen bei allen vier Items zwischen 75,0% und 91,6% liegen und somit als relativ hoch anzusehen sind. Schließlich sind auch die jeweiligen Assoziationsmaße für alle vier Variablen sehr hoch.

Variablen, deren Stabilitäten über alle drei Wellen als nicht akzeptabel angesehen werden müssen, sind "letzte berufliche Stellung" (55,7%), "berufliche Stellung des Vaters" (52,1%) und "erste berufliche Stellung" (42,0%).

Dies ist jedoch nicht überraschend wenn wir uns vergegenwärtigen, daß bei diesen Fragen von den Interviewten jeweils eine beträchtliche Klassifikationsleistung gefordert wird: Die Befragten müssen ihre jeweilige berufliche Stellung bzw. die ihres Vaters einer der 32 (bzw. beim Vater sogar 37) vorgegebenen Antwortkategorien zuordnen.

Alle diese Ergebnisse bestätigen eine allgemeine Erklärung für die Antwortstabilität von Variablen: Je größer die Anzahl der Antwortkategorien ist, um so mehr nimmt die Antwortstabilität ab.

Betrachten wir im folgenden die vier Fragen nach den beruflichen Stellungen etwas genauer: Wie Koch (1985: 67f) zurecht anmerkt, muß der Interviewte bei der Beantwortung dieser Fragen zwei Arten von Differenzierungen leisten: Zunächst muß er unter den rechtlich-institutionell definierten Stellungen im Beruf "seine" Stellung wiederfinden (z.B. Arbeiter, Angestellter). Im zweiten Schritt muß er dann eine Differenzierung im hierarchischen Niveau innerhalb des gewählten Oberbegriffs vornehmen (ungelernter Arbeiter, angelernter Arbeiter usw.).

Wie aus der nachstehenden Tabelle E hervorgeht, scheinen die Befragten mit der ersten Differenzierung (Einordnung in die Hauptkategorien) wenig Probleme zu haben. Sehen wir von der Frage nach der "ersten beruflichen Stellung" ab, so können die Antwortstabilitäten als sehr gut bezeichnet werden.

Tabelle E: Antwortstabilitäten über alle drei Wellen für die Fragen nach den beruflichen Stellungen

	Nach 7 bzw. 8 Hauptgruppen differenziert			Nach 32 bzw. 37 Hauptgruppen differenziert			Prozent- satzdif- ferenz %
	N	S	%	N	S	%	
Derzeitige berufliche Stellung	63	62	98.4	63	46	73.0	25.4
Letzte berufliche Stellung	61	55	90.2	61	34	55.7	34.5
Erste berufliche Stellung	131	73	55.7	131	55	42.0	13.7
Berufliche Stellung des Vaters	140	113	80.7	140	73	52.1	28.6

Offensichtlich stellt das eigentliche Problem für den Befragten die Einordnung "seiner" beruflichen Stellung in die entsprechende Subkategorie dar, d.h. wenn der Befragte nach 32 bzw. 37 Subkategorien differenzieren muß, sinken die Antwortstabilitäten über alle drei Wellen drastisch ab (bis zu 34,5%).

Neben dieser zu großen Anzahl von Antwortkategorien sind die verschiedenen Vorgaben in den Subkategorien teilweise den Befragten nicht geläufig (zu generelle Bezeichnungen), oder sie sind nicht trennscharf genug<sup>12)</sup>.

Als Folgerung aus diesen Ergebnissen schlagen wir für zukünftige Befragungen vor, diese Frage zweigeteilt zu erheben (Frage 1 nach der Hauptkategorie, Frage 2 nach der zugehörigen Subkategorie) und die Subkategorien präziser zu formulieren.

Sehr hohe Antwortstabilitäten zeigen sich bei einer weiteren Fragengruppe, nämlich den fünf Fragen nach den beruflichen Tätigkeiten. Bei keiner dieser "offen" gestellten Fragen (derzeitige berufliche Tätigkeiten von Selbständigen und Nicht-Selbständigen, erste und letzte berufliche Tätigkeit sowie die berufliche Tätigkeit des Vaters) fallen die Stabilitäten über alle drei Wellen unter 78%.

Wie Koch hierzu ausführt, entspricht die Aufforderung, eine Berufsbezeichnung unter Bezug auf die Tätigkeitsinhalte zu nennen, einer weitgehend im Alltag üblichen Konvention der Berufsklassifikation. Da die Nennung einer solchen konkreten Berufsbezeichnung für die Befragten die Wiederholung einer oft geübten Leistung darstellt (Koch 1985: 66) fallen die Antwortstabilitäten entsprechend hoch aus.

Diese fünf Fragen ohne standardisierte Antwortvorgaben werden also von den Befragten sehr reliabel beantwortet. Die sich aus dieser Feststellung unmittelbar ergebende Frage, ob und falls ja in welchem Ausmaß "offene" Fragen zuverlässiger beantwortet werden als standardisierte Fragen zum gleichen Sachverhalt läßt sich ebenfalls mit der Test-Retest-Studie untersuchen. Die Frage nach der Branche, in der der Befragte derzeit arbeitet wurde sowohl

offen als auch mit standardisierten Antwortvorgaben (31 Antwortkategorien) vorgelegt.

Ausgehend von der Überlegung, daß die Zuordnung einer Branchenbeschreibung zu einem Wirtschaftszweig durch speziell qualifizierte Vercoder besser geleistet wird als durch die Befragten, müßte die Reliabilität der offenen Frage höher sein als die der geschlossenen. Diese Hypothese wird durch die Daten bestätigt: Während 93,7% aller Befragten über alle drei Wellen die offene Frage stabil beantworten, sind dies bei der geschlossenen Frage "nur" 83,9%.

Dieses Ergebnis sollte jedoch nicht vorschnell so interpretiert werden, daß sämtliche Fragen in allgemeinen Bevölkerungsumfragen in Zukunft "offen" formuliert werden sollten, zumal dies schon aus Kostengründen nicht möglich ist.

Als erstes Zwischenresümee können wir festhalten, daß Fragen, die komplexe, aber für den Befragten unmittelbar alltagsrelevante Probleme zum Thema haben, möglicherweise besser in offener Form gestellt und von geschulten Vercodern klassifiziert werden sollten. Fragen mit vorgegebenen Antwortkategorien werden dann sehr reliabel beantwortet, wenn die Antwortvorgaben klar und eindeutig formuliert, gegeneinander klar abgegrenzt und die Informationen für die Befragten leicht "abrufbar" sind.

Bei den intervallskalierten sozio-demographischen Variablen erhalten wir erfreulich hohe Antwortstabilitäten sowohl bei der Frage nach dem Alter wie auch bei der Kinderzahl der Befragten. Die Stabilitäten über alle drei Wellen erreichen bei beiden Fragen fast 100%.

Beim Vergleich der Antworten über die drei Wellen für die beiden Fragen nach dem Alter bei der ersten Heirat (für verheiratete bzw. verwitwete oder geschiedene Befragte) und bei den Angaben zur wöchentlichen Arbeitszeit können die Ergebnisse als noch befriedigend bezeichnet werden<sup>13)</sup>.

Auf den ersten Blick unbefriedigende Resultate ergeben sich bei den restlichen intervallskalierten Demographievariablen. Vor allem bei der für

Sozialstrukturanalysen zentralen Variablen "Einkommen" machen nur 26,8% der Befragten über alle drei Wellen exakt dieselbe Angabe.

Allerdings sind diese Abweichungen nicht so dramatisch, wie dies zunächst den Anschein hat: Wie wir den Daten entnehmen können, geben viele Befragte in einer Welle das genaue Einkommen an, z.B. 2030,-DM, machen aber in der nächsten Welle nur noch eine gerundete Angabe, in diesem Fall also 2000,-DM. Dies wird auch evident bei einer Betrachtung der Korrelationskoeffizienten: So zeigen sich in allen drei Beziehungen zwischen den Wellen Korrelationskoeffizienten von über 0.900, d.h. die Zusammenhänge der Einkommensangaben sind zwischen den einzelnen Wellen sehr hoch.

Darüberhinaus weisen die nach Heise (1969) berechneten Schätzwerte für die Reliabilitäten und die Stabilitäten sämtlicher intervallskalierter Demographievariablen äußerst befriedigende Ergebnisse auf. Für alle Variablen betragen die Reliabilitäten mindestens .968; die Stabilitäten zwischen den Wellen liegen bei fast allen Variablen zwischen .900 und 1.000.

Abschließend sei noch auf ein äußerst interessantes Ergebnis verwiesen, das im nächsten Kapitel eingehender diskutiert werden soll: Bei fast allen demographischen Variablen sind die Antwortstabilitäten zwischen der zweiten und der dritten Welle höher als diejenigen zwischen Welle eins und zwei bzw. eins und drei.

### 2.2.2 Einstellungsvariablen

Vergleichen wir die Antwortstabilitäten der Einstellungsfragen in Tabelle 5 des Arbeitsberichtes mit denen der demographischen Variablen, so zeigen sich erwartungsgemäß bei fast allen Einstellungsitems erheblich niedrigere Antwortstabilitäten sowohl im Vergleich von je zwei wie auch über alle drei Wellen.

Lediglich zur Frage nach der subjektiven Schichteinstufung sowie zu den Fragen nach ihrem vergangenen bzw. zukünftigen Wahlverhalten scheinen die Befragten festgefügte Meinungen bzw. eine gute Rückerinnerung zu haben: Rund

80% aller Interviewten gaben nämlich bei allen drei Befragungen jeweils die gleiche Antwort.

Untersuchen wir zunächst wieder die kategorialen Variablen, deren Ergebnisse in den Tabellen 5A und 5B des beiliegenden Arbeitsberichts ausgewiesen sind.

Bei den Fragen zum Wohlfahrtsstaat zeigen sich nur bei drei Items (Item D: "Staatliche Fürsorgepflicht", Item F: "Gutes Leben in der BRD" und Item G: "Gerechte Verteilung") Antwortstabilitäten von rund 50% über alle drei Wellen. Zu diesen Items, die eher generelle Einstellungen zum Wohlfahrtsstaat thematisieren, existiert bei den Befragten offensichtlich auch ein relativ festgefügtes Meinungsbild.

Neben dieser eher inhaltlichen Erklärung dürfte jedoch auch noch ein fragetechnischer Faktor für die höheren Stabilitäten gegenüber den anderen fünf Items <sup>14)</sup> verantwortlich sein: Alle drei Items weisen jeweils nur einen Stimulus auf, während dies bei den restlichen Items meist nicht der Fall ist. <sup>15)</sup> So könnte beispielsweise eine Befragungsperson bei Item A in der ersten Welle als Stimulus den ersten Satz des Items ("Jeder muß für sich selbst sorgen"), bei der nächsten Welle den zweiten Satz mit Betonung auf politischem Kampf und bei der letzten Welle diesen zweiten Satz mit Betonung auf gewerkschaftlichem Kampf beantwortet haben. <sup>16)</sup>

Während bei einigen Items zum Wohlfahrtsstaat noch Stabilitäten von ca. 50% aufgetreten sind, finden sich bei den Ungleichheitsitems keine Stabilitäten in dieser Höhe. Die besten Werte erhalten wir bei dem letzten Item, bei dem immerhin noch über 40% der Befragten dreimal die gleiche Antwort geben. Während die anderen Items zur Ungleichheit noch von ca. jedem dritten Befragten über alle drei Wellen stabil beantwortet werden, fällt Item A in der Stabilität völlig ab und weist mit 22.5% einen äußerst niedrigen Wert auf. Wir führen dieses Ergebnis vor allem auf den doppelten Stimulus, der in diesem Item enthalten ist, zurück. <sup>17)</sup>

Neben dem Problem doppelter Stimuli dürften für die relativ niedrigen Stabilitäten der Wohlfahrts-, aber in noch stärkerem Maße der

Ungleichheitsitems die mangelnde Trennschärfe der Antwortkategorien verantwortlich sein.<sup>18)</sup>

Analysieren wir die Häufigkeitsverteilungen pro Welle, so sehen wir, daß die meisten Befragten eine der beiden mittleren Antwortkategorien angeben (ausweichen?) und sich die Instabilitäten vor allem aufgrund eines Pendelns zwischen diesen beiden Antwortkategorien ergeben.

Die starke Konzentration auf eine der beiden mittleren Antwortkategorien dürfte im Übrigen auch darauf zurückzuführen sein, daß sich einige Interviewte durch die Fragen zu den Themen Wohlfahrtsstaat und Ungleichheit intellektuell überfordert fühlten oder sich zu diesen Fragen noch keine Meinung gebildet hatten. Anstatt nun mit offener Meinungslosigkeit zu reagieren (also mit "weiß nicht" zu antworten) versuchten sie eine inhaltliche Antwort zu geben; in der Regel wichen sie auf die mittleren Antwortkategorien aus. Eher zufällig entschieden sie sich dann für die eine oder die andere der beiden mittleren Antwortkategorien.

Gerade die Frage, ob sich eine Befragungsperson bereits mit einem Thema auseinandergesetzt hat bzw. ob ein Themengebiet für den Befragten eine bestimmte Relevanz hat, wirkt sich erheblich auf die Antwortstabilität und auch die Reliabilität aus. So weist Converse (1970) darauf hin, daß die unterschiedliche Zentralität, die ein Erhebungsobjekt für den Befragten hat, für die Höhe der Fluktuation seiner Antworten in Panelstudien entscheidend ist. Leider können wir diese These mit unserem Datenmaterial nicht weiter verfolgen.

Betrachten wir noch die Ergebnisse der Fragen zu politischen Wertorientierungen (Inglehart-Index): Die höchsten Stabilitätswerte über alle drei Wellen erhalten wir beim wichtigsten und beim unwichtigsten Ziel, d.h. die Befragten scheinen diese beiden Ziele noch - relativ gesehen - eindeutig festlegen zu können, während das zweit- und das drittwichtigste Ziel eher zufällig bestimmt wird. Dies wirkt sich insofern dramatisch aus, als das zweitwichtigste Ziel für die Zuordnung der Befragten zu den



Inglehartschen Wertetypen von zentraler Bedeutung ist. Der in vielen empirischen Arbeiten verwandte Index ist also nach den Daten dieser Studie auf Individualebene über die Zeit ein instabiles Instrument.

Auf den ersten Blick weisen die vier intervallskalierten Gastarbeiter-Items (vgl. Tabelle 5C des Arbeitsberichts) keine befriedigenden Antwortstabilitäten auf. Nur jeweils jeder vierte Befragte nennt in allen drei Wellen denselben Skalenwert für ein bestimmtes Item. Dieses Ergebnis ist jedoch nicht überraschend, wenn wir uns vergegenwärtigen, daß dem Befragten jeweils eine Skala mit 7 Ausprägungen vorgelegt wurde.

Wesentlich aussagekräftiger als die Antwortstabilitäten von Randverteilungen sind für die Beurteilung der Items sicherlich die aus den Korrelationskoeffizienten errechneten Reliabilitäten und Stabilitäten der Items (vgl. Tabelle 6 des Arbeitsberichts). Während die Reliabilitäten mit Werten zwischen .755 und .956 sehr hoch sind, können die Stabilitäten zwischen den Wellen bis auf wenige Ausnahmen als bestenfalls zufriedenstellend bezeichnet werden.<sup>19)</sup>

Wenden wir uns abschließend den Antwortstabilitäten der Parteienthermometer zu. Von den beiden extremen Parteien NPD und DKP abgesehen bewegen sich die Antwortstabilitäten über alle drei Wellen nur zwischen 18.3 und 27.5%. Allerdings sollten wir bei diesen Werten beachten, daß wir es hier mit Antwortskalen zu tun haben, die dem Befragten 11 (!) Möglichkeiten der Einordnung bieten, d.h. wir müssen von vornherein niedrige Antwortstabilitäten erwarten. Die sehr hohen Stabilitäten für die beiden radikalen Parteien NPD und DKP scheinen zwar diese Aussage zu relativieren, jedoch ist dieses Ergebnis darauf zurückzuführen, daß die Mehrzahl der Befragten diese Parteien in allen drei Wellen extrem schlecht (meist mit -5) bewertet hat.

Wesentlich bedeutsamer sind auch bei der Analyse der Ergebnisse zum Parteienthermometer die Reliabilitäten und Stabilitäten der Items. Sowohl die Reliabilitäten mit Werten zwischen .700 und .856 als auch die Stabilitäten mit Werten zwischen .900 und 1.000 sind für die Items beeindruckend hoch. Lediglich die Stabilitäten für die SPD und bei der FDP zwischen Welle 1 und 3 (Stabilitäten zwischen .664 und .817) müssen als

nicht befriedigend eingestuft werden. Offensichtlich haben aber die Befragten der Test-Retest-Studie ein relativ festgefügtes Meinungsbild von den sechs Parteien, das in den hohen Stabilitäten zum Ausdruck kommt.

Abschließend kommen wir zu einem der zentralen Ergebnisse der Test-Retest-Studie, auf das bereits im vorhergehenden Kapitel kurz hingewiesen wurde. Wir haben unsere bisherigen Analysen vor allem auf die Höhe der Antwortstabilitäten über alle drei Wellen konzentriert. Vergleichen wir dagegen die Stabilitäten zwischen den jeweiligen Befragungswellen, so können wir eine interessante Regelmäßigkeit konstatieren: Bei fast allen demographischen und Einstellungsvariablen sind die Antwortstabilitäten zwischen der zweiten und der dritten Welle höher als zwischen der ersten und der zweiten bzw. der ersten und der dritten Welle.<sup>20)</sup>

Als Ursache für dieses Ergebnis vermuten wir, daß sich die Befragten erst beim zweiten Interview bewußt waren, daß sie noch ein drittes Mal befragt würden<sup>21)</sup> und sie deshalb die beiden letzten Interviews ernsthafter durchgeführt haben, d.h. valider als in der Hauptstudie geantwortet haben.

Darüberhinaus ist es auch möglich, daß sich die Befragten nach dem ersten Interview mit den Themen der Umfrage auseinandergesetzt haben bzw. "unbewußt" Informationen zu den angesprochenen Themen gesammelt haben.

Welche von diesen beiden Erklärungen zutrifft, können wir anhand des vorliegenden Datenmaterials nicht entscheiden. Hierzu wären weitere Untersuchungen erforderlich.

### 3. Zusammenfassung und Bewertung

Neben der Beschreibung der Test-Retest-Studie zum ALLBUS 1984 setzte sich dieser Abschlußbericht mit zwei Fragen auseinander.

Im ersten Teil sind wir der Frage nachgegangen, inwieweit die Test-Retest-Stichprobe repräsentativ für die ALLBUS-Haupterhebung ist. Vergleiche der Häufigkeitsverteilungen zentraler Variablen wie auch der Vergleich der

Kovarianzmatrizen mehrerer Einstellungsfragen zeigten, daß die Test-Retest-Studie in der Tat ein verkleinertes Abbild der ALLBUS-Hauptstudie darstellt.

Im zweiten Teil diskutierten wir die Antwortstabilitäten ausgewählter Variablen über alle drei Wellen. Obwohl keine der demographischen Variablen eine Antwortstabilität von 100% über alle drei Wellen erreichte, waren die Stabilitäten von allen für die Analyse von Umfragedaten zentralen soziodemographischen Variablen außerordentlich hoch. Die Frage, wie stabil Umfragedaten eigentlich sind, findet zumindest soweit es die demographischen Variablen angeht an den Daten der Test-Retest-Studie eine ermutigende Antwort.

Im Vergleich zu diesen Variablen sind die Antwortstabilitäten über alle drei Wellen bei den Einstellungsvariablen erwartungsgemäß niedriger. Dies ist aber offensichtlich sehr häufig ein Resultat der Operationalisierung der Variablen.

Für die Höhe der Antwortstabilitäten scheinen vor allem fragetechnische Aspekte ausschlaggebend zu sein. So hat die Zahl der Antwortkategorien bzw. der Range der Skalen einen erheblichen Einfluß auf die Stabilitäten, d.h. Je geringer die Anzahl der Antwortkategorien ist bzw. Je kürzer die Skalen sind, umso stabiler sind in der Regel die Antworten und vice versa.

Erhebliche Auswirkungen auf die Antwortstabilitäten zeigen sich darüberhinaus, wenn Fragen nicht eindeutig formuliert sind und mehr als einen Stimulus enthalten oder die Antwortkategorien nicht ausreichend trennscharf sind.

Ein weiteres zentrales Ergebnis ist, daß die Antwortstabilitäten zwischen der zweiten und dritten Welle bei fast allen Variablen höher sind als diejenigen zwischen Welle 1 und 2 bzw. Welle 1 und 3. Wir können nur vermuten, daß bei den Befragten zwischen der ersten und zweiten Welle "verschiedene Sensibilisierungs-, Motivations- und Lernprozesse" (vgl. Koch 1985: 61) abgelaufen sind, die sich bereits auf das Antwortverhalten in der zweiten Welle ausgewirkt und letztlich ihren Niederschlag in den höheren Antwortstabilitäten zwischen Welle 2 und 3 gefunden haben.

#### 4. Veröffentlichungen

Auf Vorschlag der ALLBUS-Antragsteller hat sich im Juli 1984 eine "Arbeitsgruppe Test-Retest" konstituiert, deren Ziel es war, die Daten dieser Methodenstudie auszuwerten. In über 2jähriger Arbeit hat diese Gruppe mehrere Beiträge zu komplexen statistischen Problemen der Panel-Analyse verfaßt, die im Mai 1987 im Rahmen eines Sammelbandes der Zeitschrift "Sociological Methods and Research" publiziert werden. Folgende Beiträge werden in diesem von George Bohrnstedt, Peter Ph. Mohler und Walter Müller herausgegebenen Band vorgestellt:

Rolf Porst und Klaus Zeifang: A Description of the German General Social Survey (ALLBUS) Test-Retest-Study and a Report on the Stabilities of the Demographic Variables

Wolfgang Jagodzinski und Steffen M. Kühnel: The Estimation of Reliability and Stability in Metric Single Indicator Multiple Wave Models

Wolfgang Jagodzinski, Steffen M. Kühnel und Peter Schmidt: Is there a "Socratic Effect" in Non-Experimental Panel Studies? Consistency of an Attitude Towards Guestworkers

Rolf Porst, Peter Schmidt und Klaus Zeifang: Comparison of Subgroups by Models with Multiple Indicators

Frank Faulbaum: Intergroup Comparisons of Latent Wave Means

Gerhard Arminger: Misspecification, Asymptotic Stability and Ordinal Variables in the Analysis of Panel Data

Darüberhinaus hat Achim Koch eine Diplom-Arbeit über die Stabilität von kategorialen Variablen in der Test-Retest-Studie verfaßt: "Wie zuverlässig lassen sich Berufs- und Bildungsvariablen messen?". Geplant ist die Veröffentlichung der zentralen Ergebnisse seiner Arbeit in einer Fachzeitschrift.

Desweiteren wurde von Wolfgang Jagodzinski in den ZA-Informationen Nr. 19 ein Beitrag mit dem Titel "Black & White statt LISREL? Wie groß ist der Anteil von Zufallswerten beim Postmaterialismusindex?" veröffentlicht.

Schließlich wird in den ZUMANACHRICHTEN Nr. 20 ein Beitrag von Rolf Porst und Klaus Zeifang unter dem Titel "Wie stabil sind Umfragedaten?" erscheinen.

Darüberhinaus hat Klaus Zeifang den beiliegenden Materialband mit Ergebnissen der Test-Retest-Studie zusammengestellt.

Die Daten der Test-Retest-Studie werden im Frühjahr 1987 an das Zentralarchiv in Köln zur Archivierung weitergegeben. Der Retest-Datensatz wird dann - wie alle ALLBUS-Studien - allgemein zugänglich sein.

Anmerkungen

- 1) Eine detaillierte Begründung für ein 3-welliges Panel wurde bereits im Antrag zum ALLBUS 1984, S. 21f. gegeben.
- 2) Ein "Stichprobennetz" stellt eine systematische Unterstichprobe aus den ca. 50.000 Stimmbezirken der Bundesrepublik und West-Berlins bei Wahlen zum Deutschen Bundestag bzw. zum Berliner Abgeordnetenhaus dar (zur Stichprobenziehung vgl. Kirschner 1984). Jedes Stichprobennetz besteht aus 210 sample points (= Stimmbezirke bzw. synthetische Stimmbezirke).
- 3) Um Verwechslungen mit den Tabellennummern des beiliegenden Arbeitsberichts zu vermeiden, wurden die Tabellen dieses Abschlußberichts mit Buchstaben gekennzeichnet.
- 4) Die ausführliche Dokumentation des Vergleichs der Randverteilungen sowie die Kovarianzmatrizen finden sich im ZUMA-Arbeitsbericht von Klaus Zeifang (Tabellen 1 und 2), der diesem Bericht als Anlage beigelegt ist.
- 5) In der letzten Alterskategorie "89 und mehr Jahre" ist in der Hauptstudie nur eine Person enthalten, so daß die erwartete Zellenhäufigkeit mit 0.05 äußerst niedrig ist. Da die erwartete Zellenhäufigkeit u.a. im Nenner der Berechnungsformel für  $\chi^2$  steht, erhöht sie den  $\chi^2$ -Wert für diese Kategorie erheblich (um 16.457 Punkte), d.h. ohne diese Alterskategorie würde der  $\chi^2$ -Wert mit 7.969 bei vier Freiheitsgraden keine Unterschiede der beiden Verteilungen signalisieren.
- 6) Die Ursache für diese Verzerrung ist wieder in der Berechnungsformel des  $\chi^2$ -Werts zu sehen: Vor allem die drei Zellen mit erwarteten Zellenhäufigkeiten, die kleiner als 1 sind, tragen zu einer exorbitanten Erhöhung des  $\chi^2$ -Werts bei. Ein visueller Vergleich der beiden Verteilungen zeigt uns jedoch, daß die Prozentwerte der beiden Stichproben ungefähr miteinander übereinstimmen.
- 7) Eine detaillierte Darstellung der Ergebnisse findet sich in Tabelle 1 des Arbeitsberichts von Klaus Zeifang (1987).
- 8) Detaillierte Informationen über Kovarianzen, Mittelwerte und Standardabweichungen sind Tabelle 2 des Arbeitsberichts zu entnehmen.
- 9) Lediglich beim Parteienthermometer zeigen sich kleinere Abweichungen, die jedoch noch nicht signifikant sind.

- 10) Eine alternative Vorgehensweise wäre durch die Berechnungen von entsprechend angepaßten log-linearen Modellen möglich gewesen (vgl. Bishop, Tienberg und Holland 1975). Da jedoch die wesentlichen Informationen über die Itemstabilität auch durch die von uns gewählte einfachere Methode erhältlich sind, haben wir uns für diese Vorgehensweise entschieden.
- 11) Die Abweichungen der Geschlechtsangabe in der dritten Welle bei einer Person ist wahrscheinlich auf einen Interviewerfehler zurückzuführen.
- 12) Dies dürfte insbesondere auf die fünf Angestelltenkategorien zutreffen.
- 13) Die Prozentwerte für diese drei Fragen betragen zwischen 69,4% und 83,7%.
- 14) Die Antwortstabilitäten über alle drei Wellen liegen bei diesen Items zwischen 30.6% und 38.5%.
- 15) Diese Mehrdeutigkeit war in Kauf genommen worden, um diese Itembatterien aus einer älteren Studie exakt replizieren zu können.
- 16) Das Item hieß: "In unserer Gesellschaft muß jeder für sich schauen, daß er auf einen grünen Zweig kommt. Es hilft nicht viel, sich mit anderen zusammenzuschließen, um politisch oder gewerkschaftlich für seine Sache zu kämpfen".
- 17) Auch diese Itembatterie wurde aus einer älteren Studie exakt repliziert. Item A hieß: "In der Bundesrepublik bestehen noch die alten Gegensätze zwischen Besitzenden und Arbeitenden. Die persönliche Stellung hängt davon ab, ob man zu der oberen oder unteren Klasse gehört."
- 18) Die Antwortkategorien hießen: "stimme voll zu", "stimme eher zu", "stimme eher nicht zu", "stimme überhaupt nicht zu".
- 19) Die Antwortstabilitäten schwanken zwischen den Wellen von .591 bis .861; nur bei drei Items liegen sie zwischen Welle 2 und 3 über .900.
- 20) Die Stabilitäten zwischen Welle 1 und 2 bzw. 1 und 3 sind häufig sehr ähnlich, wobei bei einigen Variablen die Stabilität zwischen Welle 1 und 2, bei anderen die zwischen Welle 1 und 3 höher ist.
- 21) Aus dem Text der Einwilligungserklärung ging hervor, daß die Befragten noch zweimal befragt werden könnten.

Arminger, G., 1976: Anlage und Auswertung von Paneluntersuchungen. S. 134 - 235 in K. Holm (Hrsg.), Die Befragung 4. München: Francke

Bishop, Y.M.M., S.E. Tienberg und P.W. Holland, 1975: Discrete Multivariate Analysis: Theory and Practice. Cambridge, Mass.: MIT Press

Campbell, D.T. und J.C. Stanley, 1966: Experimental and Quasi-Experimental Designs for Research. Chicago, Ill.: Rand McNally

Converse, Ph.E., 1970: Attitudes and Non-Attitudes: Continuation of a Dialogue. S. 168 - 189 in E. R. Tufte (Hrsg.), Quantitative Analysis of Social Problems. Reading, Mass.: Addison-Wesley

Heise, D.R., 1969: Separating Reliability and Stability in Test-Retest-Correlation. S. 93 - 101 in American Sociological Review 34

Heise, D. R. und G.W. Bohrnstedt, 1970: Validity, Invalidity and Reliability. S. 104 - 129 in E. F. Borgatta und G. W. Bohrnstedt (Hrsg.), Sociological Methodology 1970. San Francisco: Jossey Bass

Jöreskog, K.G. und D. Sörbom, 1977: Statistical Models and Methods for Analysis of Longitudinal Data. S. 285 - 325 in D. J. Aigner und A. S. Goldberger (Hrsg.), Latent Variables in Socioeconomic Models. Amsterdam: North Holland

Kessler, R.C. und D.F. Greenberg, 1981: Linear Panel Analysis. Models of Quantitative Change. New York, London: Academic Press

Kirschner, H.-P., 1984: ALLBUS 1980: Stichprobenplan und Gewichtung. S. 114 - 182 in K. U. Mayer und P. Schmidt (Hrsg.), Allgemeine Bevölkerungsumfrage der Sozialwissenschaften. Beiträge zu methodischen Problemen des ALLBUS 1980. ZUMA-Monographien Sozialwissenschaftliche Methoden, Band 5. Frankfurt, New York: Campus

Koch, A., 1985: Wie zuverlässig lassen sich Berufs- und Bildungsvariablen messen? Diplomarbeit Universität Mannheim

Lord, F.M. und M.R. Novick, 1968: Statistical Theories of Mental Test Scores. Reading, Mass.: Addison-Wesley



Müller, W., F.U. Pappi, E.K. Scheuch und R. Ziegler, 1983: Antrag auf Gewährung einer Sachbeihilfe zum Thema Allgemeine Bevölkerungsumfrage der Sozialwissenschaften (ALLBUS 1984). Mannheim: unveröffentlicht

Porst, R. und P. Schmidt, 1982: Analyse ausgewählter Meßinstrumente des ALLBUS 1980. Mannheim: unveröffentlicht

Wiley, D.E. und J.A. Wiley, 1970: The Estimation of Measurement Error in Panel Data. S. 112 - 117 in American Sociological Review 35

Zeifang, K., 1987: Die Test-Retest-Studie zum ALLBUS 1984 - Tabellenband. Mannheim: ZUMA