

Computerunterstützte Inhaltsanalyse -CUI- bei offenen Fragen

Klingemann, Hans-Dieter; Mohler, Peter Ph.

Veröffentlichungsversion / Published Version

Zeitschriftenartikel / journal article

Zur Verfügung gestellt in Kooperation mit / provided in cooperation with:

GESIS - Leibniz-Institut für Sozialwissenschaften

Empfohlene Zitierung / Suggested Citation:

Klingemann, H.-D., & Mohler, P. P. (1979). Computerunterstützte Inhaltsanalyse -CUI- bei offenen Fragen. *ZUMA Nachrichten*, 3(4), 3-19. <https://nbn-resolving.org/urn:nbn:de:0168-ssoar-210706>

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.

ZUMA

COMPUTERUNTERSTÜTZTE INHALTSANALYSE (CUI)

BEI OFFENEN FRAGEN⁺

Forschungsstatistiken zeigen, daß derzeit bei ungefähr einem Drittel in der Bundesrepublik durchgeführter sozialwissenschaftlicher Forschungsprojekte inhaltsanalytische Verfahren in mehr oder weniger großem Umfang eingesetzt werden. Kaum mehr als ein Viertel dieser Projekte verwendet allerdings explizit algorithmisierte (d.h. für den EDV-Einsatz geeignete) Verfahren der Textklassifikation (MOCHMANN & IMMER, 1979). Wir meinen, daß der Grund für den geringen Anteil von Inhaltsanalysen, die sich maschineller Hilfsmittel bedienen, in mangelnder Information über CUI und einer Fehleinschätzung ihrer Möglichkeiten zu suchen ist. Nach 'Nachrichtenwerte und Computerunterstützte Inhaltsanalyse' in den ZUMANACHRICHTEN Nr. 2 soll deswegen hier ein weiteres Beispiel für den sinnvollen und im Vergleich zu konventionellen ('manuellen') Inhaltsanalysen nutzbringenden Einsatz automatisierter Verfahren in der Hoffnung dargestellt werden, damit einen Beitrag zur Verbesserung der Kommunikation in diesem Bereich zu leisten.

Mangelnde Kommunikation dürfte im übrigen nicht die einzige Ursache nur sporadischer Nutzung der Möglichkeiten automatischer Inhaltsanalyse sein. Es fehlen - zumindest in der BRD - außerdem die institutionellen Voraussetzungen für eine größere Verbreitung. So fehlen nach wie vor Forschungseinrichtungen und Datenarchive mit primär inhaltsanalytischer Ausrichtung und damit die Grundbedingungen für langfristige Forschungsperspektiven. Daneben mangelt es auch an leicht exportierbarer Software, also an Datenanalysepaketen, die Texte mit Hilfe standardisierter Techniken erschließen können. Inhaltsanalytische Technologien, wie etwa der GENERAL INQUIRER (STONE et al., 1966) und WORDS (IKER + HARWAY, 1969) können wegen sprachspezifischer Probleme nicht so problemlos übernommen werden wie die Analysepakete (z.B. SPSS und OSIRISS) für numerische Datenverarbeitung. Damit fehlen nicht zuletzt auch wichtige Hilfsmittel für die praktische datenbezogene Ausbildung im Bereich der inhaltsanalytischen Methodologie.

⁺ Dieser Beitrag über ein spezielles Anwendungsgebiet computerunterstützter Inhaltsanalyse ersetzt stellvertretend einen ausführlicheren Bericht über den ZUMA-Workshop "Elektronische Inhaltsanalyse" im September 1978. Der sich anschließende Beitrag gibt in diesem Zusammenhang einen Überblick über verfügbare deutsche Diktionäre.

Hier und da sind allerdings auch Fortschritte zu verzeichnen. In Ulm wird z.B. gegenwärtig eine Datenbank für Texte aus der Psychoanalyse aufgebaut (GRÜNZIG, 1979). In Münster sollen größere Bestände von Zeitungen und Zeitschriften in maschinenlesbare Formate übertragen werden (SCHÖNBACH, 1979), und bei ZUMA werden im Rahmen unserer Möglichkeiten sowohl Analysepakete (derzeit TEXTPACI und COCOA) als auch eine Reihe von Diktionären (Klassifikationsschemata) bereitgestellt.

OFFENE VERS. GESCHLOSSENE FRAGEN

Bei seinen Arbeiten zur Methodenentwicklung hat sich ZUMA auch der Frage zugewandt, ob der Einsatz von CUI im Bereich der Umfrageforschung Erfolg verspricht. "Textdaten" werden in Umfragen immer dann produziert, wenn den Befragten eine 'offene' Frage vorgelegt wird, zu der sie frei, d.h. mit eigenen Worten, Stellung nehmen sollen.

In den frühen Jahren der Umfrageforschung gab es eine oft dogmatisch geführte Diskussion über den Nutzen offener oder geschlossener Frageformulierungen. Von dieser Kontroverse, die Paul F. LAZARSELD bereits 1944 auf ihren harten Kern reduzierte, ist heute nicht mehr viel zu spüren. (LAZARSELD, 1944: 38 - 60). Man ist sich einig, daß beide Frageformen spezifische Vor- und Nachteile besitzen, die sie für unterschiedliche Meßprobleme unterschiedlich gut geeignet sein lassen (SCHEUCH, 1967: 146 - 147). Generell ist zu sagen, daß die geschlossene Frage als Meßinstrument angemessen ist, wenn sich die Strukturierung des zu messenden Sachverhalts im Bewußtsein des Befragten mit der vom Forscher vorgenommenen Einengung der Reaktionsmöglichkeiten durch die Formulierung bestimmter Antwortalternativen deckt. Ist dies nicht der Fall, so empfiehlt sich die Verwendung der offenen Frage.

Diese generellen Hinweise sollen nicht verdecken, daß es innerhalb beider Kategorien höchst unterschiedliche Fragentypen gibt. Die Vertrautheit der Befragten mit dem angesprochenen Themenkreis (Erinnerungsleistung, Verbalisierungsfähigkeit) und die Komplexität des Stimulusobjekts (Dimensionalität der Beantwortungsmöglichkeiten) sind nicht an die Form der Frage gebunden. Deshalb ist sowohl für die

offene als auch für die geschlossene Frage eine große Variationsbreite im Schwierigkeitsgrad der Beantwortung festzustellen. Die in der Literatur zu findende Diskussion der Vorzüge und der Nachteile einer Verwendung offener Fragen bezieht sich in der Regel auf Fragen mit hohem Schwierigkeitsgrad und komplexem Stimulusobjekt. Läßt man diese Einschränkung gelten, so wird als Vorteil der offenen Frage gewertet, daß

- a) die Antworten des Befragten durch vorgefaßte Meinungen des Forschers nicht verzerrt werden,
- b) die Einstellungen des Befragten nuancierter und vollständiger erfaßt werden können, und
- c) die Möglichkeit überraschender Einsichten größer ist.

Als Nachteile werden angeführt:

- a) die Abhängigkeit des erhobenen Materials von der Qualität der Interviewer, und
- b) die Schwierigkeiten der quantitativen Analyse der aufgezeichneten Reaktionen der Befragten (SCHEUCH, 1967: 146).

Einmütigkeit besteht darin, daß offene Fragen einen höheren Aufwand erfordern; ein prinzipieller Einwand gegen die offene Frage kann daraus allerdings nicht abgeleitet werden. Die angeführten Nachteile haben dazu beigetragen, daß in der Praxis geschlossene Fragen häufig auch dann vorgezogen werden, wenn die methodischen Argumente für eine Verwendung offener Fragen sprechen.

KONVENTIONELLE VERS. MASCHINELLE CODIERUNG

Für die Probleme, die bei der Codierung der Antworten auf offene Fragen entstehen, gibt SCHUMAN (1974) ein drastisches Beispiel. Schumann verglich Praktiken der Kinderpflege in den Jahren 1953 und 1971. Bei gleicher Fragestellung und gleichem Codierschema ergab sich ein theoretisch und statistisch signifikanter Unterschied, dem SCHUMANN allerdings mißtraute. Er ließ die noch verfügbaren Antworten der Umfrage aus dem Jahre 1953 durch die Codierer, die das Datenmaterial aus dem Jahre 1971 verschlüsselt hatten, noch einmal verschlüsseln. Der Unterschied

verschwand, ein Sachverhalt, der sich bei Verwendung computerunterstützter Verfahren nicht ergeben hätte.

FRISBIE/SUDMAN (1968) haben im Rahmen des National Opinion Research Centers der Universität von Chicago als erste mit dem Einsatz computerunterstützter Techniken in der Umfrageforschung experimentiert. Sie haben dabei auf den an der Harvard Universität entwickelten General Inquirer zurückgegriffen (STONE et al., 1966). Für die Zwecke ihrer Analyse haben sie das Harvard III General Inquirer Dictionary um einige Kategorien (tags) erweitert.

In ihren Experimenten beschäftigten sie sich mit drei unterschiedlichen Problemen:

1. mit der Vercodung manifeste Inhalte von Antworten auf Fragen, die üblicherweise sehr lange Listen für Antwortvorgaben bzw. für die Vercodung der Antworten erfordern (list information responses).
Beispiel: What kind of work do you do?
2. mit der Vercodung manifeste Inhalte von Antworten auf Fragen, die ein bestimmtes Thema ansprechen (thematic responses).
Beispiel: Everybody these days has some things he worries about - some big, some small. What about the big things? What would you say has worried you or been on your mind most in the past few weeks?
3. mit der Vercodung latente Inhalte von Antworten auf Fragen, die ein bestimmtes Thema ansprechen (latent responses).
Beispiel: What have you been concerned about recently?

Die Ergebnisse zeigten wenig Schwierigkeiten im Hinblick auf die Vercodung der manifesten Inhalte der Antworten. Nach FRISBIE und SUDMAN bedürfen lediglich zwischen 10% und 15% der "list information responses" einer interpretierenden Bearbeitung durch konventionelles Vercodungspersonal.

Ein Vergleich zwischen den Resultaten manueller und computerunterstützter Vercodung von Antworten auf themenbezogene offene Fragen nach ihrem manifesten Inhalt ergab eine Übereinstimmung (=korrekte Vercodung) von 84%, d.h. 16% der Codes stimmten nicht überein. Bei diesen nicht übereinstimmenden Vercodungen traf die computerunterstützte und die manuelle Methode zu je 50% die korrekte Kategorie. Beide Vorgehensweisen erbrachten also 92% korrekte Codezuweisungen und damit keinen Unterschied im Hinblick auf die Qualität der Verschlüsselung.

ZUMA

Die Verwendung des modifizierten Harvard III General Inquirer Dictionary (National Opinion Research Center Idiomatic Dictionary) für die Vercodung latenter Inhalte der Antworten erwies sich als problematisch. Zwischen Befragten, die sich zu einem unterschiedlichen Grade persönlich Sorgen machten (a lot, not very much, never), ergaben sich ebensowenig interpretierbare Differenzen im Hinblick auf die Verwendung bestimmter Konzepte (roles, status; social, physical things; social areas, behavior; psychological themes; denial) wie zwischen solchen Befragten, die auf einem "positive bzw. negative feeling index" (BRADBURN/CAPLOVITZ 1965: 15 - 24) unterschiedliche Positionen einnahmen (high,low). Lediglich Personen, deren Antworten einen hohen Grad von Affekt aufwiesen, zeigten sich eher personenorientiert als solche, die weniger affektiv antworteten. Die interessanteste Feststellung bestand darin, daß die Befragten mehr über ihre Sorgen sprachen (d.h. mehr Wörter für die Beantwortung der Frage benötigten), die einen hohen Wert im Hinblick auf irgendeine der angeführten Fragen oder Skalen erreichten (worried a lot; high positive feelings; high negative feelings; high affect level). FRISBIE und SUDMAN vermuten, daß die enttäuschenden Resultate bei dem Versuch, latente Dimensionen zu vercoden, weniger an der Verfahrensweise als an der Entwicklung tragfähiger Konzepte liegt: "Unfortunately, as in this case, many an attractive conceptualization will probably fade in the bright glare of the empirical results" (FRISBIE/SUDMAN 1968: 230).

Insgesamt kommen FRISBIE und SUDMAN zu positiven Schlußfolgerungen, was die technische Seite ihrer Erfahrung mit computerunterstützter Vercodung offener Fragen angeht. Sie weisen aber auch zu Recht auf die finanziellen Investitionen hin, die nötig sind, um ein solches System zu entwickeln. Unter dem Aspekt einer langfristigen Nutzung kommen sie jedoch auch im Hinblick auf die finanzielle Seite der computerunterstützten Vercodung zu einer positiven Beurteilung.

"To summarize, we have shown that we can do as well using computer as manual methods to code free-response information; that the computer method can be very expensive if put only to limited use, but less expensive than manual methods if used repeatedly; and that the computer has several advantages over manual coding methods" (FRISBIE/SUDMANN 1968: 225).

ZUMA

BERUFSCODIERUNGEN

Für seine eigenen Forschungen auf diesem Gebiet der Methodenentwicklung verwendet ZUMA das Textanalysesystem TEXTPACK (HÖHE et al., 1978). Dieses System wird von ZUMA gewartet und an Interessenten weitergegeben.

Anknüpfend an die Überlegungen von FRISBIE und SUDMAN haben wir uns zunächst dem Problem der computerunterstützten Bearbeitung von Listeninformationen zugewandt. Dabei ging es um die Verschlüsselung von Berufstätigkeiten, eine Angabe, die in nahezu jeder Umfrage vorkommt. Zwei Klassifikationsschemata für die Vercodung von Berufstätigkeiten wurden operational definiert: Die Internationale Standardklassifikation der Berufe (ISCO), die von der International Labour Organization in Genf verwendet wird (291 Kategorien) und die Klassifikation beruflicher Tätigkeiten nach der Systematik des Statistischen Bundesamtes (328 Kategorien). Das computerunterstützte Verfahren ist der konventionellen Verschlüsselung in vieler Hinsicht überlegen und hat sich im Forschungsalltag des Instituts bewährt, wie wir an anderer Stelle ausführlich berichtet haben, (KLINGEMANN/SCHÖNBACH, 1977; SCHÖNBACH/KLINGEMANN, 1978; SCHÖNBACH 1977).

DER PARTEI-IMAGE-DIKTIONÄR

Ermutigt durch die Ergebnisse dieser Arbeiten haben wir uns danach dem Problem der computerunterstützten Vercodung manifester Inhalte von Fragen zugewandt, die ein bestimmtes Thema ansprechen (thematic responses). Dabei haben wir als Testobjekt ein Klassifikationsschema gewählt, für das maschinenlesbare Textdaten aus anderen, nicht von ZUMA getragenen Forschungsaktivitäten bereits vorlagen. Dieses komplexe Klassifikationsschema wurde zunächst für die konventionelle Verschlüsselung der Einstellungen zu politischen Parteien in Deutschland entworfen (KLINGEMANN, 1976). Seine Bedeutung gewinnt es im Zusammenhang mit Fragestellungen, die sich auf die Erforschung der Einstellungskomponenten der Wahlentscheidung richten. Forschungsprobleme dieser Art wurden in den USA vor allem von STOKES (1958, 1966) unter Verwendung von Daten bearbeitet, die mit Hilfe von offenen Fragen nach den guten

und den schlechten Seiten der politischen Parteien erhoben wurden. Die Ergebnisse dieser Untersuchungen haben die empirische Wahlforschung außerordentlich befruchtet.

Die Entwicklung des deutschen Klassifikationsschemas baut auf den Arbeiten des Center for Political Studies, ISR, University of Michigan, auf, geht in seiner Systematik jedoch über das in den USA verwendete Schema weit hinaus.

Es basiert auf dem 'Argument', als kleinste Einheit der Verschlüsselung.

Dabei werden die folgenden Aspekte unterschieden:

- a) Der Typ der Eigenschaft der politischen Partei.
- b) Die Einstellung des Befragten zu dieser Eigenschaft (positiv/negativ).
- c) Die Art der Verknüpfung der so bewerteten Eigenschaft mit der politischen Partei (assoziativ/dissoziativ).
- d) Die zeitliche Gültigkeit des Arguments.

Dabei folgt aus der Verknüpfung von 'b' und 'c' die Einstellung des Befragten zu der politischen Partei, soweit es das betrachtete Argument betrifft.

Unser Operationalisierungsversuch für die computerunterstützte Verschlüsselung bezieht sich zunächst auf die Erfassung des Typs der Eigenschaften, die mit den politischen Parteien in der Vorstellung der Bevölkerung verbunden werden.

In Tabelle 1 ist die Typologie der Eigenschaften, die wir operational definiert haben, abgebildet.

ZUMA

TAB. 1

TYOLOGIE DER EIGENSCHAFTEN VON POLITISCHEN PARTEIEN

- I SPEZIFISCHE EIGENSCHAFTEN
 - 1 IDEOLOGISCHE EIGENSCHAFTEN
 - 11 LINKS
 - 12 PROGRESSIV
 - 13 DEMOKRATISCH
 - 14 LIBERAL
 - 15 KONSERVATIV
 - 16 RADIKAL
 - 17 CHRISTLICH
 - 10 SONSTIGE IDEOLOGISCHE EIGENSCHAFTEN
 - 2 EIGENSCHAFTEN BEZOGEN AUF SOZIALE GRUPPEN
 - 21 KIRCHEN
 - 22 OBERSCHICHT
 - 23 MITTELSCHICHT
 - 24 UNTERSCHICHT
 - 25 DAS VOLK
 - 26 ALTE LEUTE
 - 27 JUNGE LEUTE
 - 20 SONSTIGE AUF SOZIALE GRUPPEN BEZOGENE EIGENSCHAFTEN
 - 3 EIGENSCHAFTEN BEZOGEN AUF INNENPOLITIK
 - 31 WIRTSCHAFTSPOLITIK
 - 32 LOHN- UND PREISPOLITIK
 - 33 ARBEITS- UND BESCHÄFTIGUNGSPOLITIK
 - 34 SOZIALPOLITIK
 - 35 STEUERPOLITIK
 - 36 BILDUNGSPOLITIK
 - 37 INNERE SICHERHEIT, RUHE UND ORDNUNG, RECHTSPOLITIK
 - 38 BUNDESWEHR
 - 39 INNENPOLITIK ALLGEMEIN
 - 30 SONSTIGE AUF INNENPOLITIK BEZOGENE EIGENSCHAFTEN
 - 4 EIGENSCHAFTEN BEZOGEN AUF AUSSENPOLITIK
 - 41 DEUTSCHLANDPOLITIK
 - 42 OSTPOLITIK
 - 43 WEST- UND BÜNDNISPOLITIK
 - 44 EUROPÄISCHE EINZELSTAATEN
 - 45 DRITTE WELT
 - 46 AUSSENPOLITIK ALLGEMEIN
 - 40 SONSTIGE AUF AUSSENPOLITIK BEZOGENE EIGENSCHAFTEN

ZUMA

- 5 EIGENSCHAFTEN BEZOGEN AUF REGIERUNG, OPPOSITION UND PARTEI
 - 51 REGIERUNGS- UND OPPOSITIONSLEISTUNG
 - 52 KOALITIONSVERHALTEN
 - 53 POLITISCHE MORAL
 - 54 PROGRAMMATIK
 - 55 SELBSTDARSTELLUNG
 - 56 ORGANISATION
 - 57 PARTEIGRUPPIERUNGEN
 - 50 SONSTIGE AUF REGIERUNG, OPPOSITION UND PARTEI
BEZOGENE EIGENSCHAFTEN

- 6 EIGENSCHAFTEN BEZOGEN AUF POLITIKER
 - 61 KANZLER, KANZLERKANDIDAT DER SPD
 - 62 KANZLER, KANZLERKANDIDAT DER CDU/CSU
 - 63 PARTEIFÜHRER FDP
 - 64 PARTEIFÜHRER CSU
 - 65 POLITIKER DER SPD
 - 66 POLITIKER DER CDU/CSU
 - 67 POLITIKER DER FDP
 - 68 POLITIKER ALLGEMEIN
 - 60 SONSTIGE AUF POLITIKER BEZOGENE EIGENSCHAFTEN

- 7 UNPOLITISCHE EIGENSCHAFTEN
 - 71 UNREFLEKTIERTE PARTEI-IDENTIFIKATION
 - 72 UNPOLITISCHE MERKMALE

- II UNSPEZIFISCHE EIGENSCHAFTEN
 - 8 UNSPEZIFISCHE EIGENSCHAFTEN
 - 81 KATEGORISCHE BEWERTUNG
 - 82 KEINE UNTERSCHIEDE ZWISCHEN DEN PARTEIEN
 - 80 SONSTIGE UNSPEZIFISCHE EIGENSCHAFTEN

- III KEINE EIGENSCHAFTEN GENANNT
 - 9 KEINE EIGENSCHAFTEN
 - 91 POLITISCHES DESINTERESSE
 - 98 WEISS NICHT
 - 99 KEINE ANGABE

Bei dem von uns angewandten Verfahren der 'a-priori-Kategorisierung' werden Worte, die nach Ansicht des Forschers im Sinne seines Untersuchungsansatzes vergleichbare Bedeutung haben, zu Listen (Kategorien, tags) zusammengefaßt und bei der Analyse die Häufigkeit einer Kategorie pro Zählinheit ermittelt (Satz, Absatz, Dokument usw.). Ein aus solchen Listen gebildetes Kategorienschema (Diktionär) ist eine explizite Operationalisierung der jeweiligen Fragestellung. Inwieweit dabei das Kategorienschema die gesuchten sprachlichen Merkmale auch tatsächlich mißt, ist theoretisch weitgehend ungeklärt (z.B. Problem der Homogenität von Sprache in unterschiedlichen Texten, Verzerrungen durch spezifische Kompetenz des Forschers).

Man verläßt sich in der Regel - so auch wir - auf das Sprach- und Theorienverständnis von Experten, ein Sachverhalt, der nicht unproblematisch ist.

Aber auch bei einer solch pragmatischen Vorgehensweise ist der Aufwand für die Erarbeitung eines "Wörterbuches", das die operationale Definition der Kategorien des Klassifikationsschemas enthält, nicht trivial. Er ist nur dann zu rechtfertigen, wenn ein breites Interesse an einer wiederholten Verwendung des Klassifikationsschemas zu erwarten ist. Dieses Interesse kann im Falle des Codes für die Verschlüsselung der Einstellungen zu den politischen Parteien angenommen werden.

Das Vokabular der politischen Alltagssprache der deutschen Bevölkerung ist wenig erforscht, ein entsprechendes "Wörterbuch" uns nicht bekannt. Eine generelle und umfassende Definition der Kategorien des Klassifikationsschemas kann in einer solchen Situation nicht versucht werden. Die Alternative besteht in einer kumulativen Definitionsstrategie, einer Strategie, die wir auch im Falle der Definition der Berufstätigkeiten angewendet haben. Konkret bedeutet dies, daß zur Definition der Kategorien zunächst solche Wörter herangezogen werden, die in den Antworten der Befragten empirisch tatsächlich vorkommen. Diese Definitionen werden dann im Verlauf weiterer Erhebungen in systematischer Weise ergänzt. Dabei können wir nach den Erfahrungen mit dem Wörterbuch der Berufstätigkeiten davon ausgehen, daß die Rate der neu hinzukommenden Wörter mit steigender Zahl der Erhebungen rasch abnimmt. Mit Hilfe eines

ZUMA

Computerprogramms (WORDCOMP) können diese neuen Wörter schnell bestimmt und übersichtlich dargestellt werden.

Die Datenbasis für unseren ersten Operationalisierungsversuch der politischen Alltagssprache der deutschen Bevölkerung bestand aus dem maschinenlesbaren Textdatenband der Vorwahluntersuchung des Jahres 1972. 1588 Befragte waren hier aufgefordert worden, zu den guten und schlechten Seiten der CDU/CSU, der SPD und der FDP Stellung zu nehmen. Die entsprechenden Interviewertranskripte umfaßten insgesamt 66.350 Wörter, davon waren 5.979 (9 Prozent) voneinander verschiedene Wörter (unter Einschluß aller Flexionen). Diese Wörter wurden in einer alphabetisch geordneten Liste mit Querverweisen zur jeweiligen Fundstelle zusammengestellt (Programm XREF). Aus dieser Liste wählten "Experten" 1591 (26,6 Prozent) Wörter als Indikatoren für die Kategorien des Klassifikationsschemas aus. Reduziert auf die Grundformen ergab sich ein Wörterbestand für die Kategoriendefinition von 566 Wörtern.

Inzwischen wurde die Datenbasis durch weitere Studien verbreitert. Die maschinenlesbaren Textdaten haben nunmehr einen Umfang von 208.041 Wörtern. An der Ergänzung der Kategoriendefinitionen wird derzeit gearbeitet. In diesem Bericht beziehen wir uns jedoch nur auf die Daten aus dem Jahre 1972.

Nach der Logik der Vorgehensweise bestand das Resultat des ersten Schrittes der Wörterbuchkonstruktion in der Auswahl von Stichwörtern, von denen angenommen wurde, daß sie die zu operationalisierenden Kategorien in eindeutiger Weise definierten. Dem Aufbau des Klassifikationsschemas entsprechend, ergab sich die in Tabelle 2 dargestellte Struktur des Wörterbuchs. Die ausgewählten Stichwörter wurden zu Grundformen zusammengefaßt und diese dann den Ober- und Unterkategorien des Klassifikationsschemas zugeordnet. Dabei erfolgte die Zusammenfassung der Wörter zu Grundformen vornehmlich unter dem Gesichtspunkt ihres semantischen Gehalts.

Die Annahme der Eindeutigkeit der ausgewählten Stichwörter wurde jedoch nur hilfsweise eingeführt. Wir erwarteten das Auftreten mehrdeutiger Stichwörter, wollten diese Frage aber empirisch, d. h. durch eine Inspektion der Stichwörter im Satzzusammenhang, angehen. Die hierfür notwendigen KWIC-Listen (key-word-in-context) können durch ein TEXTPACK - Unterprogramm auf einfache

ZUMA

TAB.2

Struktur der Wörterbucheintragungen

Analytische Kategorien	Grundform	Operationalisierung
1 Ideologische Eigenschaften	001 Kommunismus	01 ALTKOMMUNISTEN
		02 ANTIKOMMUNISTISCH
		03 DKP
11 Links		04 KOMMUNISMUS
		05 KOMMUNISTEN
		06 KOMMUNISTENFREUNDLICH
		07 KOMMUNISTIN
		08 KOMMUNISTISCH
		09 KOMMUNISTISCHE
		10 KOMMUNISTISCHEN
		11 KOMMUNISTISCHER

Weise erzeugt werden. Dieser pragmatische Ansatz lag nahe, weil über Art und Umfang des Mehrdeutigkeitsproblems für die deutsche Sprache, und bezogen auf den Erfahrungsbereich "Politische Parteien", unseres Wissens keine systematischen Analysen vorliegen.

Aus Tabelle 3 geht das Gewicht des Mehrdeutigkeitsproblems für unsere Fragestellung hervor. 9 Prozent der von uns zur Kategoriendefinition herangezogenen Wörter wurden in mehr als einem Bedeutungszusammenhang gebraucht. Dies hat zur Folge, daß unter der Annahme der Eindeutigkeit 11,3 Prozent der maschinell zugewiesenen Codes falsch gewesen wären (dabei wären die Eigenschaftstypen "Regierung, Opposition und Partei" sowie "Politiker" davon besonders betroffen gewesen). Anders ausgedrückt bedeutet dies insgesamt eine Verlässlichkeit der automatischen Verschlüsselung auf der Basis von Stichwörtern von 89 Prozent, ein Wert, der bei einer konventionellen Verschlüsselung - in Anbetracht des komplexen Klassifikationsschemas - durchaus noch tolerabel ist. Wir führen die relativ geringe Mehrdeutigkeitsquote darauf zurück, daß durch die Vorgabe eines spezifisch auf politische Sachverhalte ausgerichteten Bezugsrahmens Mehrdeutigkeiten nur noch innerhalb des so eingeschränkten Bedeutungsbereichs auftreten können.

ZUMA

TAB. 3

Fehlerhafte Verschlüsselung aufgrund mehrdeutiger Wörter

Kategorien des Klassifikations-schemas	Anzahl der Wörter, die insgesamt zur operationalen Definition der Kategorien verwendet wurden	Darunter: Anzahl der mehrdeutigen Wörter		Insgesamt vergebene Codes	Fälschlich zugewiesene Codes	
	n	n	%	n	n	%
Ideologische Eigenschaften	249	17	6.8	1072	66	6.2
Eigenschaften bezogen auf soziale Gruppen	210	13	6.2	1054	167	15.9
Eigenschaften bezogen auf Innenpolitik	387	17	4.4	1621	112	6.9
Eigenschaften bezogen auf Außenpolitik	134	9	6.7	1312	26	2.0
Eigenschaften bezogen auf Regierung, Opposition und Partei	473	74	15.6	3028	520	17.2
Eigenschaften bezogen auf Politiker	138	14	10.1	1747	216	12.4
Insgesamt	1591	144	9.0	9834	1107	11.3

Das Wort "Rechte" ist ein typisches Beispiel für Mehrdeutigkeit innerhalb des politischen Bedeutungsbereichs. So wurde für positiv oder negativ gehalten:

- "Daß sie Rechte für Deutschland wahren."
- "Es sind zu viele Rechte in der Partei".
- "Sie können Ihre Erfolge nicht ins rechte Licht stellen."

ZUMA

Das Textanalysepaket TEXTPACK bietet mit TEXTLING eine benutzerorientierte Sprache an, die es erlaubt, komplexe Ausdrücke zu definieren. Wörter können, unter Berücksichtigung ihrer Stellung im Satz, logisch verknüpft werden. Will man etwa die ideologische Bedeutung des Wortes "Rechte" fassen, so lautet die entsprechende Anweisung im Wörterbuch: 'RECHTE' VOR 'PARTEI'. Es würde also nur dieser im Sinne der Kategorie 15 "Konservativ" richtige Indikator zur Verschlüsselung der Antworttexte verwendet.

Mehrdeutigkeiten so auszuschalten ist natürlich thema- und textspezifisch und hat aus sprachtheoretischer Sicht erhebliche Schwächen. Ein genereller Ansatz ist allerdings, wie KELLY/STONE (1976) zeigen konnten, nur dann sinnvoll, wenn mit dem 'disambiguierer' regelmäßig sehr große Textdaten verarbeitet werden sollen; dies ist jedoch vorläufig in Deutschland noch nicht der Fall.

Abschließend möchten wir einen speziellen Vorteil der expliziten operationalen Kategoriendefinition hervorheben. Gleiche analytische Begriffe verdecken oft den Bedeutungswandel, dem solche Begriffe im Zeitverlauf unterworfen sind. Ein Bedeutungswandel dieser Art kann sichtbar gemacht werden, wenn man den relativen Anteil der verschiedenen Wörter-Grundformen betrachtet, die als Indikatoren für eine bestimmte analytische Kategorie bestimmt wurden. Die Tabelle 4 soll diese Überlegung illustrieren. Hieraus geht hervor, daß die Grundformen "Links", "Kommunismus" und "Sozialismus" den Bedeutungsgehalt der Kategorie "Links" zu 92 Prozent im Jahre 1972 determinieren. Die übrigen vier Grundformen tragen also nur noch minimal zu ihrem Bedeutungsgehalt bei. Dieser Sachverhalt kann sich aber prinzipiell ändern, und das Wissen um solche Veränderungen kann die Interpretation entscheidend beeinflussen.

Die beschriebenen Bemühungen um eine für die computerunterstützte Inhaltsanalyse geeignete operationale Definition der Kategorien bezogen sich, wie eingangs betont, zunächst auf einen speziellen Aspekt des Standardcodes für die Einstellungen zu den

ZUMA

TAB. 4

Inhaltliche Definition der Kategorie "Links"

Wortstamm	Laufende Nummer der Wortstämme	Kumulative Häufigkeit der Nennungen	
		n	%
LINKS	1	134	59.8
KOMMUNISMUS	2	170	75.9
SOZIALISMUS	3	206	92.0
ROT	4	217	96.9
MARXISMUS	5	220	98.2
LENINISMUS	6	222	99.1
PROLETARIAT	7	224	100.0

politischen Parteien. Es ging um die Bestimmung des Typs der Eigenschaften, die mit den politischen Parteien verbunden wurden. Entsprechende Arbeiten im Hinblick auf die Bewertung dieser Eigenschaften, auf die Art ihrer Verknüpfung mit den Parteien und die zeitliche Gültigkeit der Argumente wurden noch nicht in Angriff genommen. Die operationale Erfassung dieser Aspekte wirft auch weit größere Schwierigkeiten auf; sie sind durch die Vorgabe von Stichwörtern allein sicher nicht zu lösen. Solange geeignetere Verfahren noch ausstehen, ist eine gemischte Vorgehensweise angebracht, bei der den Maschinen das überlassen wird, was sie derzeit leisten können, während menschliche Vercoder den Rest besorgen.

In unserem Falle wurde der Argumententyp maschinell bestimmt. Der menschliche Vercoder muß also die Definitionskriterien der 58 entsprechenden Kategorien des Klassifikationsschemas nicht mehr im Kopf haben. Er kann sich auf die Entscheidung konzentrieren, ob die Eigenschaft, mit der die politische Partei in Verbindung gebracht wird, für den Befragten eine positive oder negative Valenz besitzt, ob diese

ZUMA

Eigenschaft mit der Partei assoziiert oder von der Partei dissoziiert wird, und welche zeitliche Gültigkeit das Argument in den Augen der Befragten hat. Diese Entscheidungen sind für die Vercoder vergleichsweise einfach, ein Umstand, der die Verlässlichkeit der Verschlüsselungsergebnisse positiv beeinflusst. Das Problem der Reduktion komplexer Antworten auf offene Fragen in Umfragen wird so verlässlicher, schneller und ökonomischer gelöst. Und damit ist ein großer Teil der Schwierigkeiten beseitigt, die der Umfrageforscher mit diesem Fragentyp gewöhnlich hat.

Weitere Auskünfte über maschinelle Inhaltsanalyse bei ZUMA geben gerne:

Hans Dieter Klingemann und Peter Ph. Mohler.

BRADBURN, N./D. CAPLOVITZ, Reports on Happiness. Chicago, Aldine, 1965.

DEICHSEL, A., Elektronische Inhaltsanalyse. Berlin: Spiess, 1975.

FRISBIE, B./S. SUDMAN, The Use of Computers in Coding Free Responses. Public Opinion Quarterly, 32, 1968, 216 - 232.

GRÜNZIG, H., Problemstellungen der Inhaltsanalyse in der Psychotherapie. Referat in der Arbeitsgruppe "Forschungsfelder computerunterstützter Inhaltsanalyse", 19. Deutscher Soziologentag, 19. April 1979, Berlin.

KELLY, E./Ph. J. STONE, Computer Aided Recognition of English Word Senses. Amsterdam: North Holland, 1976.

IKER, P./N. J. HARWAY, A Computer Systems Approach Toward the Recognition and Analysis of Content, in: GERBNER et al, The Analyses of Communication Content, New York: Wiley, 1969.

HÖHE, J./H. D. KLINGEMANN/K. RADERMACHER, TEXTPACK, Version IV, Mannheim, ZUMA, 1978.

KLINGEMANN H. D./K. SCHÖNBACH, Computerunterstützte Inhaltsanalyse als Instrument zur Vercodung offener Fragen. Paper read at the 27th Annual Conference of the International Communication Association (ICA), May 29, 1977, Berlin

KLINGEMANN, H. D., Standardcode zur Verschlüsselung der Einstellungen zu den politischen Parteien in der Bundesrepublik Deutschland, Mannheim, ZUMA, 1976.

LAZARFELD, P. F., The Controversy over Detailed Interviews - An Offer for Negotiation. Public Opinion Quarterly, 8, 1944, 38 - 60.

- MOCHMANN, E./N. IMMER, Forschungsarbeiten zur quantitativen Inhaltsanalyse in der Bundesrepublik Deutschland, Mimeo, Köln, Zentralarchiv für empirische Sozialforschung, 1979.
- SCHEUCH, E.K., Das Interview in der Sozialforschung. In: KÖNIG, R. (Hrsg.), Handbuch der empirischen Sozialforschung, Band 1, 2. Auflage, Stuttgart: Enke, 1967, 136 - 196.
- SCHÖNBACH, K., Berufsverschlüsselungen: Ein Bericht aus der Codeabteilung. ZUMANACHRICHTEN, Nr. 1, 1977, 18 - 20.
- SCHÖNBACH, K., Computerunterstützte Inhaltsanalyse in der Massenkommunikationsforschung - ein Überblick über deutschsprachige Forschungsarbeiten, Referat in der Arbeitsgruppe "Forschungsfelder computerunterstützter Inhaltsanalyse", 19. Deutscher Soziologentag, April 1979, Berlin.
- SCHUMAN, H., Old Wine in New Bottles: Some Sources of Response Error in the Use of Attitude Surveys to Study Social Change, Paper prepared for the Research Seminar Group in Quantitative Social Science, at the University of Surrey, 4 April, 1974.
- STOKES, S., Partisan Attitudes and Electoral Decision. Doctoral Dissertation, Yale University, 1958.
- STOKES, D., Some Dynamic Elements of Contests for the Presidency. American Political Science Review, 60, 1966, 19 - 28.
- STONE, Ph. J., Improved Quality of Content Analysis Categories: Computerized-Disambiguation Rules for High-Frequency English Words. In G. GERBNER et al. (eds.), The Analysis of Communication Content, New York: Wiley, 1969, 199 - 221.
- STONE, Ph. J., et al., The General Inquirer. A Computer Approach to Content Analysis, Cambridge, Mass.: M.I.T. Press.