

**Ausgabe 4
Oktober 2008**



FACHHOCHSCHULE DÜSSELDORF
UNIVERSITY OF APPLIED SCIENCES DÜSSELDORF

Forschungsberichte des Fachbereichs Wirtschaft der Fachhochschule Düsseldorf

Helmut Quack

Der Einsatz der multidimensionalen Skalierung (MDS) im nationalen und internationalen Marketing

Teil 1: Mathematische, empirische und auswertungsbezogene Vorgehensweise



Der Einsatz der multidimensionalen Skalierung (MDS) im nationalen und internationalen Marketing

Teil 1: Mathematische, empirische und auswertungsbezogene Vorgehensweise

Prof. Dr. Helmut Quack

Fachhochschule Düsseldorf
Fachbereich Wirtschaft
Universitätsstraße 1, Geb. 23.31/32
40225 Düsseldorf
helmut.quack@fh-duesseldorf.de

Abstract: Teil 1 konzentriert sich auf die praxisgerechte und verständliche Darstellung des multivariaten Verfahrens der „Multidimensionalen Skalierung“, die im Rahmen eines professionellen Marketing eine hervorgehobene Rolle einnehmen. Ausgehend von einigen Beispielen und nach der Einordnung der MDS in die multivariaten Verfahren werden die verschiedenen Arten der MDS vorgestellt. Anschließend wird erläutert, wie die „Ähnlichkeiten“ und „Präferenzen“ empirisch erhoben werden. Danach folgend wird die mathematische Vorgehensweise geschildert, wie eine mehrdimensionale Konfiguration konstruiert wird, bei der die Objekte (z.B. Produkte, Personen), die sehr ähnlich sind, nahe beieinander liegen und diejenigen, die sehr unähnlich sind, weit auseinander liegen. Im Anschluss daran werden Einzelfragen, wie z.B. Auswahl und Zahl der Objekte, Wahl der Dimensionalität sowie das Auftreten degenerierter Lösungen angeschnitten. Anschließend wird die Interpretation dieser Konfiguration mittels Merkmalsvektoren vorgestellt. Zum Schluss werden geeignete Computerprogramme benannt und Möglichkeiten des Einsatzes der MDS im Marketing kurz vorgetragen. In dem Artikel wird deutlich gemacht, dass die MDS eine ganze Reihe von Vorteilen (wenngleich auch einige Nachteile) hat. Der größte Vorteil besteht darin, dass die globalen Urteile über Ähnlichkeiten und Präferenzen ohne Vorgaben gefällt werden und erst im Nachhinein geklärt wird, worauf diese Beurteilungen beruhen. Dadurch ist ein Blick in das Innere der Konsumenten möglich.

Teil 2 wird dann die Anwendung der MDS in den verschiedenen Bereichen des Marketing, wie bspw. Analyse des Images, Festlegung der Positionierung, Segmentierung des Marktes, das Finden von einstellungsrelevanten Merkmalen sowie die Ableitung von Marketingmaßnahmen zum Gegenstand haben. Auch die internationalen Bezüge werden dann angesprochen.

1. Vorüberlegungen: Zur Sinnhaftigkeit der MDS

Die multidimensionale Skalierung ist eine von vielen multivariaten Verfahren, die mit einem anspruchsvolleren mathematischen Instrumentarium speziell dazu erhobene Daten intensiv analysieren. Man erhofft sich damit auf bisher unbekannte Zusammenhänge zu stoßen.

Die multidimensionale Skalierung kann wie folgt kurz charakterisiert werden: Mittels der erhobenen Ähnlichkeiten bzw. Präferenzen in Bezug auf Objekte (z.B. Produkte, Personen,...) kann ein psychologischer Wahrnehmungsraum konstruiert werden, der die subjektive Wahrnehmung von Objekten durch Personen räumlich abbildet. Diese so konstruierte Konfiguration kann u.a. mit Hilfe von Eigenschaftsvektoren interpretiert werden. Die Ergebnisse der Analysen können im Marketing in vielfältiger Weise verwandt werden.

Warum sollte man eine komplizierte mathematische Methode einsetzen, wenn man doch mit Hilfe einfacher Befragungen und einfacher statistischer Auswertungen gleich gute Er-

gebnisse erhält? Diese Frage werden sich viele stellen, die sich vor der Mathematik scheuen. Aber die Antwort ist zunächst sehr einfach. Man kann Menschen befragen und man erhält meist die sozial erwünschten Antworten und u.a. solche, bei denen sich die Personen objektiv-rational präsentieren. Aber diese Antworten entsprechen vielfach nicht dem tiefen Inneren der Auskunftspersonen.

Ein Beispiel dazu: Wenn man Käufer fragt, was die wichtigen Produktmerkmale für den Kauf eines Luxusautos sind, dann erhält man die sozial erwünschten Antworten: hohe Sicherheit, gute Bremsen, PS-Stärke zur Vermeidung von Unfällen, Bequemlichkeit etc. Nur wenige geben zur Antwort, dass das Image oder „das Angeben können“ für den Kauf eines Autos am wichtigsten sind. Für erfolgreiche und vielfach auch weniger erfolgreiche Menschen ist es häufig bedeutsam, ihre gesellschaftliche Stellung durch ein Luxusauto zu unterstreichen. In einer einfachen Befragung würden sie dies aber nicht zugeben. Die MDS kann jedoch solche motivationalen Zusammenhänge herausfinden.

Ein weiteres Beispiel: In einer direkten Befragung von Konsumenten bzgl. des Kaufs von Füllhaltern wurde herausgefunden, dass das Merkmal „gutes Schreiben“ als „sehr wichtig“ und das Merkmal „Eleganz“ als „unwichtig“ für den Kauf angesehen wurde. Im Rahmen einer MDS-Untersuchung des Autors war jedoch das genaue Gegenteil der Fall, d.h. die „Eleganz“ wurde als sehr wichtig, das „Schreiben“ als „unwichtig“ für den Kauf betrachtet. In weiteren Untersuchungen wurde ein erstaunliches Ergebnis zutage gefördert: Die mittels der MDS ermittelte Kaufrelevanz der Produktmerkmale korrelierte in hohem Maße mit der Erinnerungsleistung an eine Werbung, die die „Eleganz“ bzw. das „Schreiben“ zum Gegenstand hatte. Darüber hinaus konnte die Kaufbereitschaft für einen Füllfederhalter signifikant vorhergesagt werden. Demgegenüber hatte die direkte Befragung mittels der „Methode der empfundenen Wichtigkeit“ keinerlei Bezug zu Kaufbereitschaft und Erinnerungsleistung. Auch dieses Beispiel macht deutlich, dass direkte Befragungen oftmals nicht die wahre Sachlage zu Tage fördern.

Neben den Ergebnissen aus obigen Beispielen sind noch eine Vielzahl weiterer Auswertungen und daraus abgeleiteter Erkenntnisse aus den MDS-Analysen möglich (ein kurzer Hinweis dazu liefert Kapitel 9). Im Ergebnis kann festgehalten werden, dass mit Hilfe der multidimensionalen Skalierung die inneren motivationalen Zusammenhänge an die Oberfläche gebracht werden können, was vielfach einfachen Methoden versagt bleibt. Gerade für das Marketing sind jedoch solche inneren Beweggründe extrem wichtig, um Erfolg mit den Produkten sowohl in der Entwicklung als auch der Vermarktung zu haben. Besonders interessant wird der Einsatz der MDS im internationalen Marketing sein, da davon auszugehen ist, dass die Beurteilung der Ähnlichkeiten und Präferenzen durch ausländische Auskunftspersonen zu Wahrnehmungsräumen führt, die sich von denen der deutschen Konsumenten unterscheiden und auch die Relevanz von Produktmerkmalen verschieden sein wird. Daraus abgeleitet werden sich auch die Images, Positionierungen, Marktsegmentierungen etc. differenziert darstellen, zumal davon ausgegangen werden kann, dass die kulturellen Einflüsse die Bewertungen der Konsumenten aus verschiedenen Ländern maßgeblich mitbestimmen. Auf diese Sachverhalte und auch die praxisnahen Anwendungen der MDS im Marketing wird aber erst im Teil 2 eingegangen.

Im Artikel wurde auf schwierige mathematische Zusammenhänge verzichtet. Der Artikel soll hingegen Studierende und Praktiker dazu anregen, sich mit der MDS zu beschäftigen, in dem die Vorgehensweise einfach beschrieben und mit nachvollziehbaren Beispielen versehen wurde. Es wird auch nicht die Forschungsfront bei der MDS dargestellt, da diese mathematisch ziemlich anspruchsvoll ist und die entsprechenden Computerprogramme für die Verwendung in der Marketingpraxis nur mit beträchtlichem Aufwand und Sachverstand betrieben werden können. (Wer trotzdem mehr dazu erfahren möchte, dem sei Borg, Groenen 2005 und die dort zitierte Literatur empfohlen.)

2. Einordnung der MDS in die Multivariaten Verfahren

Die multidimensionale Skalierung ist nur eine von vielen multivariaten Analysetechniken. Diese sind dadurch gekennzeichnet, dass an einer Vielzahl von Objekten (z.B. Personen, Produkten,...) mehrere Variablen (z.B. Eigenschaften,...) gemessen und gleichzeitig ausgewertet werden können. Gerade im Marketing hängt z.B. die Akzeptanz eines neuen Produktes oder die Wirkung eines TV-Spots von mehreren Variablen ab. Daher genügt es nicht nur eine Variable (univariate Verfahren) oder den Zusammenhang zwischen zwei Variablen (bivariate Verfahren) zur Erklärung heranzuziehen, sondern eine Vielzahl von Faktoren muss berücksichtigt werden (vgl. auch Meffert et al. 2008, S. 172 ff.).

Um eine Vorstellung davon zu bekommen, was die anderen multivariaten Verfahren zu leisten vermögen, sollen die wichtigsten davon in aller Kürze charakterisiert werden.

Üblicherweise können die multivariaten Verfahren entsprechend ihrer primären Zielsetzung in folgende Gruppen eingeteilt werden:

- Bei den **dependenzanalytischen** bzw. **strukturprüfenden Verfahren** soll eine Überprüfung von Zusammenhängen zwischen abhängigen und unabhängigen Variablen erfolgen. Es sollen also Ursache und Wirkung herausgefunden werden.
- Bei den **interdependenzanalytischen** bzw. **strukturentdeckenden Verfahren** geht es darum, wechselseitige Beziehungen der Variablen zu untersuchen, d.h. man möchte eine Struktur in einer ungeteilten Variablenmenge entdecken.

Ziel	Verfahren
Analyse von Abhängigkeiten → Dependenzanalytische Verfahren → Strukturprüfende Verfahren	- Regressionsanalyse - Varianzanalyse - Diskriminanzanalyse - Kausalanalysen - Conjoint Measurement
Analyse wechselseitiger Beziehungen → Interdependenzanalytische Verfahren → Strukturentdeckende Verfahren	- Clusteranalyse - Faktorenanalyse - Multidimensionale Skalierung

Abbildung 1: Klassifikation wichtiger multivariater Verfahren
(vgl. Nieschlag et al. 2002, S. 477; Backhaus et al. 2006, S. 7 ff.)

Die folgenden multivariaten Verfahren werden nur in ihren grundlegenden Aspekten vorgestellt, so dass der Sinn des Verfahrens deutlich wird. Darüber hinaus wird ein typisches Beispiel für die Anwendung im Marketing und marketingnahen Bereich gegeben. Wer sich intensiver informieren möchte, findet vertiefende Darstellungen in Hermann et al. (2008), Litz (2000), Hartung, Elpelt (2007), Borg, Staufenbiel (2007), Backhaus et al. (2006), Nieschlag et al. (2002, S. 476 ff.) sowie Koch (2004, S. 234 ff.).

Regressionsanalyse: Die Wirkungsbeziehungen zwischen einer abhängigen Variable (z.B. Produktumsatz) und einer oder mehreren unabhängigen Variablen (z.B. Höhe der Werbeausgaben, Verkaufspreis, Anzahl der Besuche von Außendienstmitarbeitern) soll untersucht werden. Das Grundanliegen besteht also darin, für eine Prädiktorvariable eine lineare

Funktion (einfache Regression) bzw. für mehrere Prädiktorvariablen eine Linearkombination (multiple Regression) zu bestimmen, welche die beste Vorhersage für eine Kriteriumsvariable ermöglicht.

Varianzanalyse: Dieses Verfahren hat eine große Bedeutung, wenn die Beeinflussung von marktbezogenen Erfolgsgrößen durch Marketingmaßnahmen untersucht werden soll. Dazu werden meist Experimente durchgeführt. Es werden darin die Auswirkungen einer unabhängigen Variablen, die ein beliebiges Skalenniveau haben darf, auf eine abhängige metrisch skalierte Variable untersucht. Nach der Anzahl der einbezogenen Faktoren unterscheidet man, ob eine (einfaktoriell) oder mehrere (mehrfaktoriell) unabhängige Variablen eine Wirkung auf eine (univariat) oder mehrere (multivariat) abhängige Variablen haben. Im einfachsten Fall haben wir es also mit einer einfaktoriellen-univariaten und im komplexeren Fall mit einer mehrfaktoriellen-multivariaten Varianzanalyse zu tun. Beispielsweise wird untersucht, ob die abhängige metrische Variable „Einkommen“ von der nicht-metrischen unabhängigen Variablen „Ausbildungsniveau“ abhängig ist. Oder: Lassen sich die Unterschiede in der Markentreue auf Beruf und Alter zurückführen. Oder: Besteht ein Zusammenhang zwischen der Farbe und Größe einer Anzeige auf die Werbewirkungen (z.B. Aufmerksamkeit, Erinnerung).

Diskriminanzanalyse: Es kann untersucht werden, ob zwischen vorgegebenen Gruppen hinsichtlich einzelner Eigenschaften signifikante Unterschiede bestehen und mit welcher (Linear-) Kombination von Merkmalen sich eine bestmögliche Trennung der vorgegebenen Gruppen erreichen lässt. Darüber hinaus kann die relative Wichtigkeit einzelner Merkmale bzgl. der Einteilung in Gruppen bestimmt sowie eine Prognose erstellt werden, welcher Gruppe ein neues Element voraussichtlich zugeordnet werden kann. Beispiel: Anhand welcher Merkmale unterscheiden sich Raucher von Nichtrauchern? Oder: Anhand welcher Merkmale und deren Ausprägungen können Kreditkunden in Risikoklassen eingeteilt werden?

Kausalanalysen: Ausgehend von theoriegeleiteten Hypothesen, die eine Kausalität zwischen (auch nicht beobachtbaren) Variablen behaupten, ist es Aufgabe der Kausalanalyse zu prüfen, inwieweit die theoretisch aufgestellten Beziehungen mit den empirisch gemessenen Zusammenhängen übereinstimmen (genauer dazu: Homburg, Pflesser, Klarmann 2008). Ein Beispiel dazu: Besteht eine Abhängigkeit der abhängigen Variablen „Käufertreue“ von dem soziologischen Konstrukt „soziale Schicht“ und „Kultur“.

Conjoint Measurement: Aus globalen Präferenzen für Produkte lassen sich die relative Wichtigkeit von Produktmerkmalen und sogar der Nutzenbeitrag jeder Merkmalsausprägung ableiten. Beispielsweise kann bzgl. der Präferenz für „Biere mit Zitronengeschmack“ die prozentuale Wichtigkeit der Merkmale „Preis“, „Geschmack“, „Markennamen“ und „Flaschengestaltung“ herausgefunden werden, aber zusätzlich auch der Nutzenbeitrag der einzelnen Merkmalsausprägungen, z.B. beim Preis, der entweder 0,90 €, 1,20 € oder 1,50 € beträgt. Die Validität des Verfahrens setzt allerdings voraus, dass zum einen die entscheidenden Merkmale berücksichtigt und zum anderen die zu beurteilenden Produkte hinsichtlich der Merkmalsausprägungen systematisch variiert wurden. (vgl. dazu auch Nieschlag et al. 2002, S. 530 ff.).

Faktorenanalyse: Dieses Verfahren wird überwiegend eingesetzt, wenn es um die Reduktion bzw. Bündelung von Variablen geht, ohne dabei wesentliche Informationsverluste zu erleiden. Wenn bspw. 50 Eigenschaften eines Außendienstmitarbeiters ermittelt werden, um seinen zukünftigen Umsatzerfolg zu prognostizieren, so würde dieses Verfahren die Menge der Eigenschaften stark reduzieren (z.B. auf 2-5). Es sollen also einige wenige übergeordnete Faktoren gefunden werden, auf die sich die Merkmale zurückführen lassen.

Clusteranalyse: Ähnliche Objekte sollen in homogene Gruppen zusammengefasst werden und gleichzeitig große Unterschiede zwischen diesen so gebildeten Gruppen bestehen. Beispiel: Lassen sich die Kunden in einem Kaufhaus entsprechend ihren Bedürfnissen in ho-

homogene Kundengruppen einteilen? Oder: Auf der Basis psychografischer Merkmale von Personen sollen unterschiedliche Persönlichkeitstypen gebildet werden. Die Clusteranalyse kann auch zum Finden und zur Veranschaulichung von homogenen Objekt- bzw. Personengruppen in der MDS-Konfiguration eingesetzt werden.

Multidimensionale Skalierung: Diese Methode, die Gegenstand dieses Artikels ist, hat viele Vorteile (z.B. keine Beeinflussung der Ergebnisse durch Auswahl der Eigenschaften), aber auch durchaus einige Nachteile, wie bspw. dass die Ergebnisse einer MDS schwieriger zu interpretieren sind, da in einigen MDS-Versionen keine direkten Bezüge zu den empirisch erhobenen Eigenschaften bestehen (siehe auch Backhaus et al. 2006, S. 621 und umfangreicher Kroeber-Riel, Weinberg 2003, S. 222 ff.). Durch die Anwendung ergänzender Methoden (auf die noch später hingewiesen wird) ist es jedoch möglich, einige der Nachteile zu beheben.

Es gibt noch eine Vielzahl weiterer Verfahren, wie bspw. Kontingenzanalyse, logistische Regression, Strukturvergleichsmodelle, Korrespondenzanalyse, neuronale Netze usw. In der einschlägigen oben bereits zitierten Literatur sind dazu nähere Angaben zu finden.

3. Die verschiedenen Arten von MDS-Verfahren

Die MDS-Verfahren können hinsichtlich dreier Kriterien eingeteilt werden:

- (1) Nach dem Inhalt der Ausgangsdaten unterscheidet man zwischen Verfahren, die Ähnlichkeits- oder Präferenzdaten verarbeiten.
- (2) Nach dem Skalenniveau der Ausgangsdaten ergibt sich eine Einteilung in metrische und nichtmetrische Verfahren.
- (3) Nach dem Aggregationsgrad der Ausgangsdaten bzw. deren Verarbeitung unterteilen wir die MDS-Verfahren in aggregierende und nicht-aggregierende Verfahren.

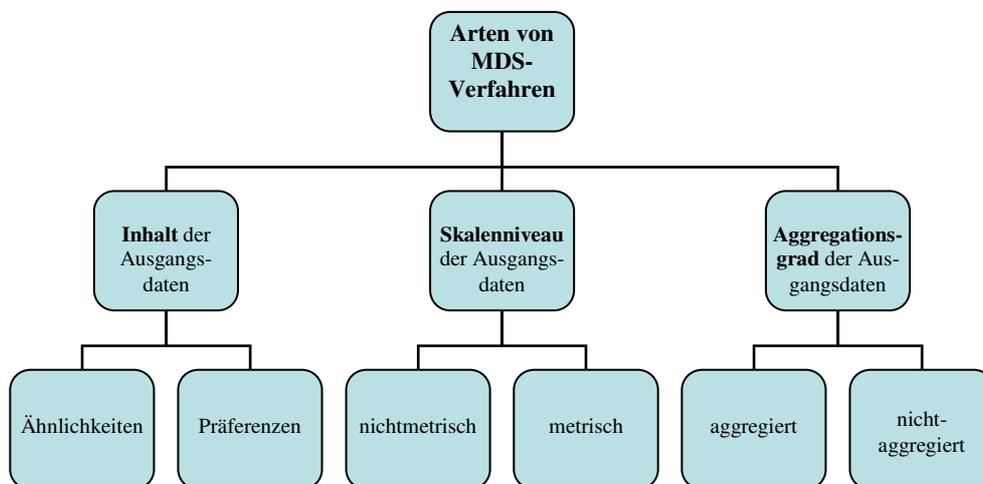


Abbildung 2: Arten der Multidimensionalen Skalierung

MDS-Verfahren lassen sich im Allgemeinen nach den Ausprägungen dieser drei Kriterien kennzeichnen. Die Kriterien sind jedoch nicht überschneidungsfrei. So gibt es beispielsweise Verfahren, die sowohl Ähnlichkeits- als auch Präferenzdaten in die Skalierung einbeziehen (z.B. die externe Präferenzskalierung; siehe auch Abschnitt 5.2).

Die einzelnen Einteilungskriterien lassen sich noch genauer charakterisieren:

Inhalt der Ausgangsdaten

Mit Hilfe der MDS-Verfahren kann man Ähnlichkeits- oder Präferenzdaten verarbeiten.

Die *Ähnlichkeit* zwischen zwei Objekten kann man veranschaulichen durch das Urteil einer Versuchsperson, wie sehr etwa zwei Produktmarken einander gleich sind oder wie sehr eine Person einer anderen Person gleicht. Die Beurteilung der Ähnlichkeit ist dabei von allgemeiner Art. Sie bezeichnet eine psychologische Verwandtschaft zwischen zwei Objekten. Die Bestimmung der Ähnlichkeit beruht auf bestimmten Merkmalen der Objekte. So beruht die Ähnlichkeit zwischen Automarken beispielsweise auf den Merkmalen Schnelligkeit, Wirtschaftlichkeit, Fahrkomfort. Bei der Abgabe der Ähnlichkeitsurteile wissen die Versuchspersonen jedoch nicht, auf welchen Merkmalen ihre Ähnlichkeitseinschätzungen basieren.

Präferenzdaten beziehen sich auf die Vorliebe für bestimmte Objekte. Als Kriterium für die Präferenz gilt die Distanz eines einem Objekt zugeordneten Punktes im mehrdimensionalen Raum vom Idealpunkt. Dieser ist ein hypothetischer Punkt einer Person (oder Personengesamtheit), der so im mehrdimensionalen Raum liegt, dass er ein Höchstmaß an Vorziewürdigkeit repräsentiert. Objekte, die nahe am Idealpunkt liegen, werden bevorzugt gegenüber Objekten, die weit vom Idealpunkt liegen.

Ein Charakteristikum der MDS besteht insbesondere darin, dass die Ähnlichkeiten und Präferenzen ohne vorgegebene Merkmale beurteilt werden. Bei anderen Erhebungs- und Analysetechniken werden oftmals umfangreiche Kataloge von Fragen abgehandelt und dabei durch entsprechende Fragen auf Eigenschaften hingewiesen, die sonst für die Urteilsbildung nicht herangezogen werden (siehe auch Nieschlag et al. 2002, 526 f.).

Skalenniveau der Ausgangsdaten

Danach unterscheidet man zwischen metrischen und nichtmetrischen Verfahren.

Die *metrischen Verfahren* sind dadurch gekennzeichnet, dass sie intervallskalierte Ausgangsdaten verlangen. In Bezug auf die Erhebung der Ähnlichkeiten bedeutet dies, dass die befragten Personen den Grad der Ähnlichkeit zwischen zwei Objekten z.B. in Prozent angeben müssen. In Bezug auf die Erhebung der Präferenzen heißt dies, dass die Befragungsperson ihre Präferenzneigung für die einzelnen Objekte z.B. auf einer Skala, die von 0 bis 100 reicht, angeben sollen.

Bei den *nichtmetrischen Verfahren* werden nur ordinale Ausgangsdaten verlangt. In Bezug auf die Ermittlung der Ähnlichkeiten bedeutet dies, dass die Auskunftsperson lediglich eine Rangfolge der Objektpaare oder eine Rangfolge mehrerer Objekte zu einem vorgegebenen Objekt hinsichtlich ihrer Ähnlichkeit anzugeben hat (siehe genauer dazu Kapitel 4). In Bezug auf die Präferenzermittlung muss die Befragungsperson nur die Präferenzrangfolge der Objekte angeben.

Obgleich die Ausgangsdaten auf ordinalem Niveau erhoben werden, liefern die nichtmetrischen Verfahren eine metrische Lösungskonfiguration, die mit derjenigen der metrischen Verfahren weitgehend übereinstimmt (zur mathematischen Begründung siehe Mathar 1997, S. 74 ff.). Zudem führt die Erhebung von Rangfolgen zu valideren Ausgangsdaten, da die Befragungspersonen in ihrem Urteilsverhalten bei der Frage nach „größer/kleiner“ sicherer und konsistenter sind als im Falle von „um wie viel größer“. Wir werden daher in diesem Beitrag nur die nichtmetrischen Verfahren berücksichtigen.

Aggregationsgrad der Ausgangsdaten

Es kann zwischen aggregierenden und nichtaggregierenden Verfahren unterschieden werden.

Die *aggregierenden* Verfahren liefern eine Endkonfiguration, die für sämtliche in die Untersuchung einbezogenen Personen gilt. Diese Vorgehensweise ist dann sinnvoll, wenn es sich um homogene Käufergruppen bzw. -segmente handelt. Häufig wird zur Aggregation der Daten der Mittelwert der Ähnlichkeitsdaten für jedes Objektpaar gebildet.

Bei den *nichtaggregierenden* Verfahren gibt es zwei wichtige Varianten:

- a. Wiederholte MDS: Die individuellen Ähnlichkeitsmatrizen der Befragungspersonen werden nicht aggregiert, sondern gemeinsam ausgewertet. Es wird unterstellt, dass ein gemeinsamer Wahrnehmungsraum existiert, dessen Homogenität überprüft wird. Es können dabei die eventuell vorhandenen Unterschiede in den Beurteilungen der Personen herausgefunden werden, ob z.B. den Beurteilungen die volle Skalenbreite zugrunde liegt oder Extreme ausgespart oder nur Werte der unteren Skalenhälfte verwendet werden. Geeignete Computerprogramme sind ALSCAL, KYST und POLYCON (letzteres allerdings nur für metrische Daten). Ein Beispiel zur Durchführung und Anwendung der sog. replizierten MDS ist Litz (2000, S. 442 f.) sowie Kappelhoff (2001, S. 45 ff.) zu entnehmen. Wenn die einbezogenen Personen ziemlich homogen sind, unterscheiden sich die Ergebnisse nicht von denjenigen bei den aggregierenden Verfahren (siehe Kappelhoff 2001, S. 48).
- b. Gewichtete MDS: Für jede der individuellen Ähnlichkeitsmatrizen wird eine andere Konfiguration erzeugt. Allerdings unterscheiden sich die individuellen Konfigurationen nicht vollständig voneinander, sondern sie basieren auf einer einzigen Konfiguration, die lediglich durch unterschiedliche Gewichtungen (mittels Stauchen oder Strecken) der Dimensionen an die individuellen Matrizen angepasst ist. Man erhält also Dimensionsgewichte für jede der n Personen. Geeignete Computerprogramme sind z.B. INDSCAL und ALSCAL. Anwendungsbeispiele für eine gewichtete MDS finden sich in Litz (2000, S. 454 ff.), der u.a. feststellt, dass die befragten Personen in homogene Gruppen einzuteilen und diese dann einer gewichteten Analyse zu unterziehen sind, um prägnante Unterschiede herauszufiltern. So ist die Betriebszufriedenheit von Angelernten, Facharbeitern und qualifizierten Angestellten zwar von den gleichen Anreizen (z.B. Lohnhöhe, Modernität der Motivationsmethoden) abhängig, aber mit deutlich unterschiedlichen Gewichten.

Bei beiden Verfahren werden die Matrizen einem Test¹ unterzogen, um Veränderungen von Wahrnehmungsräumen zu überprüfen. Insofern können auch die Ergebnisse von Messungen zu zwei verschiedenen Zeitpunkten analysiert werden. Dieses Verfahren kann z.B. in Panels oder in Experimenten verwandt werden.

Auch bei den Präferenzdaten lassen sich die oben genannten Verfahren analog anwenden (siehe Kappelhoff 2001, S. 12).

Da sich marketingrelevante Aussagen häufig auf Personengesamtheiten beziehen, reichen die aggregierenden Verfahren meist aus. Allerdings sollte zuvor überprüft werden, ob die befragten Personen in Bezug auf ihre Ergebnisse verhältnismäßig homogen sind. Falls das nicht der Fall ist, sollten homogene Zielgruppen (z.B. mittels Clusteranalysen) herausgefunden werden, auf die dann die aggregierende MDS jeweils angewandt wird oder es kann auf die o.g. disaggregierenden Verfahren zurückgegriffen werden. Im Folgenden wird auf die disaggregierenden Verfahren nicht intensiver eingegangen, da es den eher einführenden

¹Um den Unterschied zwischen zwei und mehr MDS-Konfigurationen herauszufinden, wird mittels prokrustischen Transformationen versucht, die Konfigurationen so ähnlich wie möglich zu machen. Ein Maß für die Ähnlichkeit zweier Konfigurationen ist der Kongruenzkoeffizient. Dann können die Abweichungen als Wirkungen von unabhängigen Variablen in Experimenten bzw. als Veränderung über die Zeit, wie bspw. bei einer Panelerhebung, gedeutet werden (vgl. Borg, Staufenbiel 2007, S. 175 ff. und Wührer 2008, S. 325).

Charakter dieses Artikels sprengen würde. Im Übrigen gilt: Wer den Ablauf der MDS in seinen wichtigen Teilen verstanden hat, wird meist problemlos auch die Erweiterungen verstehen. (In Teil 2 werden wir jedoch in dem einen oder anderen Praxisbeispiel auf die nicht-aggregierenden Verfahren zurückkommen.)

4. Empirische Erhebung der Ausgangsdaten

Auf welche Art und Weise kann man Ähnlichkeits- und Präferenzdaten erheben, die lediglich ordinales Skalenniveau haben?

4.1 Messung von Ähnlichkeiten

Die Erhebung der Ähnlichkeit kann mit Hilfe direkter oder indirekter Verfahren erfolgen.

Direkte Verfahren sind dadurch gekennzeichnet, dass die Ähnlichkeit von Stimuli von den Versuchspersonen eingeschätzt wird. Es werden dazu unterschiedliche Datenerhebungsverfahren eingesetzt, die weiter unten diskutiert werden.

Bei den **indirekten Verfahren** wird die Ähnlichkeit nicht unmittelbar erfragt, sondern die Ähnlichkeit wird beispielsweise aus dem Verhalten von Konsumenten oder aus Profildaten abgeleitet. So stellen Verwechslungshäufigkeiten von Stimuli ein Ähnlichkeitsmaß dar, welches aus dem Verhalten von Verbrauchern ermittelt werden kann. Man geht hierbei davon aus, dass zwei Stimuli einander ähnlicher sind, wenn sie häufiger von Konsumenten verwechselt werden. Aber auch aus Profildaten lassen sich Ähnlichkeiten ableiten. Profildaten erhält man dadurch, dass die Objekte anhand von 10 bis 15 Objektmerkmalen beurteilt werden. Anschließend wird für jedes Objektpaar ein Korrelationskoeffizient berechnet, der als Ähnlichkeitsmaß des Objektpaares gedeutet wird. (Ein anschauliches Beispiel dazu findet sich in Borg, Staufenbiel 2007, S. 160 ff.) Die weiteren zahlreichen Möglichkeiten zur indirekten Messung von Ähnlichkeiten kann Borg, Groenen (2005, S. 111 ff.) entnommen werden. In Teil II wird im Rahmen eines Praxisbeispiels auf die indirekte Messung von Proximitäten näher eingegangen.

Da die direkte Erhebung im Allgemeinen zu valideren Ergebnissen führt und zur Beantwortung von etlichen Marketingfragen gut geeignet ist, sollen nachfolgend nur die Methoden zur **Erhebung der direkten Ähnlichkeiten** besprochen werden.

In der Literatur werden eine Vielzahl von Verfahren zur Erhebung der Ähnlichkeiten beschrieben (z.B. in Green, Carmone, Smith 1989, S. 56 ff.), davon sollen jedoch nur die zwei für praktische Marktforschungszwecke wichtigsten vorgestellt werden:

Bei der *Methode der vollständigen Rangordnung* sollen die Konsumenten sämtliche Stimuluspaare in eine Rangfolge bringen. Das ähnlichste Stimuluspaar erhält den Rang 1, das unähnlichste den Rang $\binom{n}{2}$, wenn n die Anzahl der Objekte ist. Wenn man also 10 Stimuli hat, können daraus 45 Objektpaare gebildet werden. Wenn die Rangzahlen in eine Ähnlichkeitsmatrix (vgl. dazu Abbildung 5) gebracht werden, kann die Matrix vom MDS-Computerprogramm unmittelbar bearbeitet werden.

Bei der *Ankerreizmethode* werden alle n Stimuli einmal als Ankerreiz vorgegeben und der Konsument soll nun die restlichen $(n-1)$ Stimuli in abnehmender Ähnlichkeit zum Ankerreiz anordnen. Man erhält dann beispielsweise eine Matrix, wie in Abbildung 3 dargestellt.

Die Elemente der Matrix sind folgendermaßen zu interpretieren. Es wird nur zeilenweise eine Rangordnung erstellt. Die erste Zeile zeigt an, dass der Konsument das Produkt B als dem Produkt A am ähnlichsten, C als am zweitähnlichsten usw. beurteilt hat. Es gibt nun zwei Möglichkeiten der Bearbeitung dieser Matrix:

	A	B	C	D	E
A	-	1	2	3	4
B	1	-	4	3	2
C	4	2	-	3	1
D	1	4	2	-	3
E	4	2	1	3	-

Abbildung 3: Ähnlichkeitsmatrix nach der Ankerreizmethode

- Einerseits kann man die Matrix mit Hilfe der Triangularisation in eine Rangordnung sämtlicher $\binom{n}{2}$ Objektpaare überführen (siehe dazu Anmerkung bei Backhaus et al. 2006, S. 629). Die daraus entstehende Matrix dient dann als Input für eine nicht-metrische MDS.

- Andererseits wendet man auf die obige Matrix unmittelbar die Unfolding-Analyse an, wie sie genauer in Abschnitt 5.2 beschrieben wird.

Für die Ankerreizmethode gegenüber der Methode der vollständigen Rangordnung spricht vor allem die geringere Erhebungszeit (ca. 10 Minuten bei 10 Objekten gegenüber 20 Minuten bei der Methode der vollständigen Rangordnung). Wie ausführliche Studien gezeigt haben, braucht auch keine Triangularisation durchgeführt zu werden. Damit steht auch für praktische Marktforschungsaufgaben ein geeignetes Erhebungs- und Auswertungsverfahren für Ähnlichkeitsbeziehungen zur Verfügung.

4.2 Messung von Präferenzen

Die einfachste, angemessenste und am häufigsten angewandte Datenerhebungsmethode ist die Erhebung von Präferenzrangfolgen. Es gibt nun verschiedene Instruktionen zur Erhebung der Präferenzen. So kann man nach einer allgemeinen Präferenz (overall-preference) fragen oder nach einer Bevorzugung für bestimmte Gelegenheiten und Situationen. So macht es z.B. einen Unterschied in der Präferenzrangfolge, ob Personen (=Objekte) als geeignete Lebens- oder Tennispartner auszuwählen sind.

Die von der Auskunftsperson geäußerte Präferenzrangfolge kommt dadurch zustande, dass der Konsument das Objekt am meisten bevorzugt, das seinem Idealpunkt am nächsten liegt und das Objekt am wenigsten bevorzugt, das von seinem Idealpunkt am weitesten entfernt ist. Der Idealpunkt entspricht dabei dem Punkt der höchsten Vorziehungswürdigkeit. Dieser Zusammenhang kann im eindimensionalen Fall wie in Abbildung 4 veranschaulicht werden.

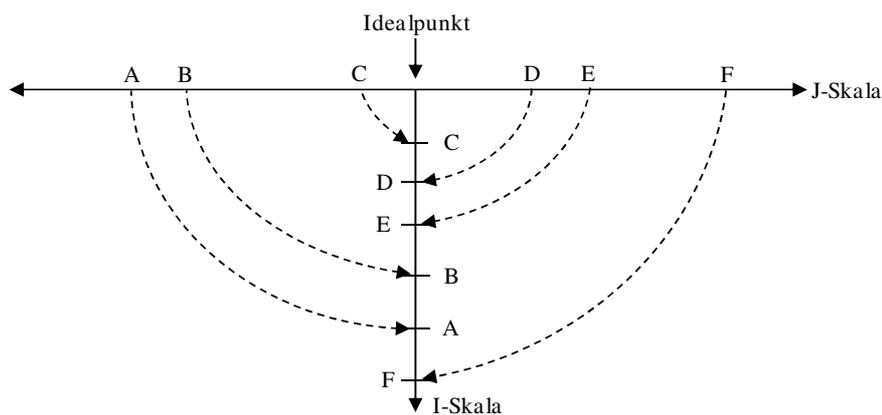


Abbildung 4.: Die Ableitung der Präferenzrangfolge

Die J-Skala (Joint scale) zeigt die Anordnung der Objekte hinsichtlich eines Merkmals und den Idealpunkt des Konsumenten. Die auf der I-Skala (Individual preference scale) angegebene Präferenzrangfolge ergibt sich dann nach dem Abstand der Objekte vom Idealpunkt (Präferenzrangfolge C, D, E, B, A, F).

5. Mathematische Vorgehensweise zur Erstellung einer Konfiguration

Im Rahmen dieses Beitrags soll auf die Rechenoperationen im Rahmen der nichtmetrischen MDS nur so weit eingegangen werden, wie es für das Verständnis des rechnerischen Ablaufs und den Einsatz dieser Methode in einer Marktforschungsuntersuchung von Bedeutung ist. Auf theoretische, mathematische Begründungen soll verzichtet werden, zumal Marketingpraktiker diese nicht unmittelbar benötigen.

5.1 Verarbeitung der Ähnlichkeitsdaten

Es soll hier zunächst der Rechengang bei einer vollständigen Ähnlichkeitsmatrix beschrieben werden. (Die von uns favorisierte Unfolding-Version stellt nur einen Spezialfall dar.) Ausgangspunkt des Verfahrens ist eine Ähnlichkeitsmatrix, bei der allen $\binom{n}{2}$ Objektpaaren hinsichtlich ihrer Ähnlichkeit eine Rangziffer zwischen 1 und $\binom{n}{2}$ zugeordnet wurde. Dabei sind Objektpaare mit kleinen (großen) Rangziffern einander sehr (un-) ähnlich.

Beispielsweise sieht eine Ähnlichkeitsmatrix für vier Objekte wie folgt aus:

	A	B	C	D
A	-	1	2	4
B	-	-	3	5
C	-	-	-	6
D	-	-	-	-

Abbildung 5: Ähnlichkeitsmatrix nach der Methode der vollständigen Rangordnung

Ziel des Verfahrens ist es nun, eine monotone Beziehung zwischen den empirisch ermittelten Ähnlichkeiten und den im mehrdimensionalen Raum ermittelten Distanzen zwischen den Objektpunkten herzustellen. Einfacher gesagt: Je ähnlicher zwei Objekte sind, umso enger sollen sie zusammen liegen. Das Verfahren berechnet - ausgehend von einer Startkonfiguration für eine vorgegebene Dimensionalität t - eine Konfiguration, die eine möglichst große Übereinstimmung zwischen Ähnlichkeiten und Distanzen aufweisen soll. Das Verfahren wird für mehrere Dimensionalitäten ausgeführt und dann wird diejenige Dimensionalität ausgewählt, die möglichst klein ist und bei der die Übereinstimmung zwischen Ähnlichkeit und Distanz groß ist. Die so ermittelte Konfiguration hat metrisches Niveau.

Dazu nun genauer:

Eine Startkonfiguration¹ für die vier Objekte in zwei Dimensionen sieht beispielsweise so wie in Abbildung 6 aus:

¹ Üblicherweise beginnt das Verfahren mit einer zufälligen Startkonfiguration. In einigen Computerprogrammen (z.B. im SPSS-Programmpaket) wird ein spezieller Algorithmus (z.B. die Young-Householder-Torgerson-Prozedur) zur Festlegung einer Startkonfiguration verwendet.

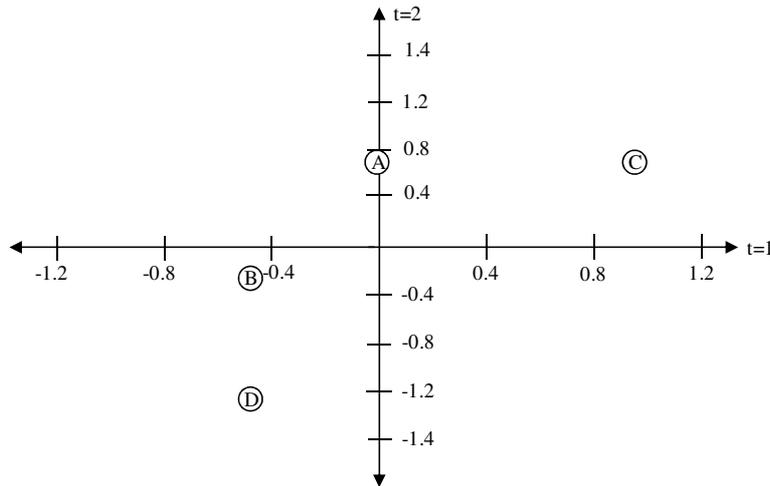


Abbildung 6: Startkonfiguration für $n=4$ Objekte in $t=2$ Dimensionen

Die numerischen Koordinatenwerte der Objektpunkte sind: A (0,0; 0,73), B (-0,49; -0,24), C (0,97; 0,73), D (-0,49; -1,21). Die Distanzen sind dann: $AB= 1,09$, $AC= 0,97$, $AD= 2,00$, $BC= 1,75$, $BD= 0,97$, $CD= 2,43$.

Distanzen und Ähnlichkeitsrangfolgen kann man nun in ein gemeinsames Koordinatensystem eintragen. Dabei werden die Objektpaare in aufsteigender Ähnlichkeitsrangfolge auf der Ordinate angeordnet. Jedem Objektpaar wird auf der Abszisse die entsprechende Distanz (in Abbildung 7 mit \bullet gekennzeichnet) zugeordnet.

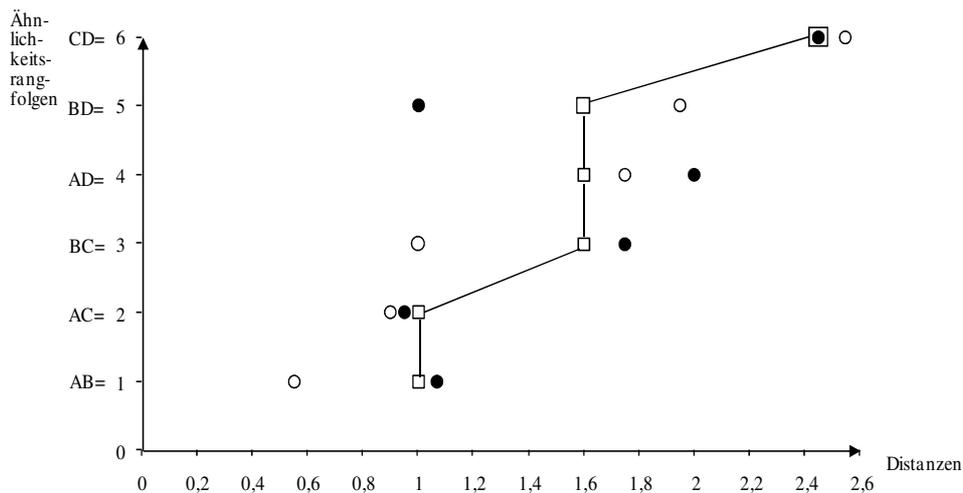


Abbildung 7: Darstellung der Distanzen zwischen den Objektpaaren und der monotonen Regressionsfunktion

Die \bullet -Punkte bezeichnen die Distanzen zwischen den Objektpaaren für die Startkonfiguration nach Abbildung 6. Die dazugehörige monotone Regressionsfunktion wird durch die durchgezogene Linie und \square gekennzeichnet. Die \circ -Punkte stellen die Distanzen für die Konfiguration nach Abbildung 9 dar.

Mit Hilfe der Methode der monotonen Regression wird nun eine monotone Kurve so in das Koordinatensystem eingezeichnet, dass die Abstände zwischen den Punkten und der Regressionskurve minimal sind (siehe Abbildung 7 durchgezogene Linie und \square).

Beim Verfahren der monotonen Regression geht man so vor, dass die Distanzwerte in Blöcke aufgeteilt werden, die das Monotoniekriterium erfüllen. Der Wert eines Blocks errechnet sich als arithmetisches Mittel der darin enthaltenen Distanzwerte (diese werden auch als Disparitäten bezeichnet). Dieser Gesamtblockwert gilt dann für die jeweils einbezogenen

Objektpaare. Für unser Beispiel ergibt sich für Block 1 (AB, AC) ein Wert von 1,03, für Block 2 (BC, AD, BD) ein Wert von 1,57 und für Block 3 (CD) ein Wert von 2,42.

Um die „Güte der Anpassung“ zwischen den Punkten im Koordinatensystem und der Regressionskurve zu ermitteln, hat Kruskal (2005, S. 49 ff.) einen Wert ermittelt, den er Stress nennt. Besonders gebräuchlich sind die Stressformeln 2 und 1.¹

Diese werden formal wie folgt ermittelt:

$$\text{Stressformel 2:} \quad \text{Stress 2} = \sqrt{\frac{\sum_{i < j} (d_{ij} - \hat{d}_{ij})^2}{\sum_{i < j} (d_{ij} - \bar{d})^2}}$$

d_{ij} : Distanzwert des Objektpaares ij auf der Abszisse

\hat{d}_{ij} : Abszissenwert der Regressionskurve beim Objektpaar ij (=Disparitäten)

\bar{d} : Mittelwert der Distanzen aller Objektpaare

Die Stressformel 1 unterscheidet sich von der Stressformel 2 dadurch, dass im Nenner nur eine Summation aller (quadrierten) Distanzen erfolgt. Zumeist liefert der Stress 1 um 50% kleinere Werte als Stress 2.

$$\text{Stressformel 1:} \quad \text{Stress 1} = \sqrt{\frac{\sum_{i < j} (d_{ij} - \hat{d}_{ij})^2}{\sum_{i < j} d_{ij}^2}}$$

Die obige Stressformel 2 wird (in leicht abgewandelter Form) im Allgemeinen auch für die Unfolding-Version benutzt, die bei der Ankerreizmethode eingesetzt wird. Stress 1 und 2 finden Anwendung in einigen MDS-Computerprogrammen, wie bspw. MDSCAL, KYST, POLYCON.

Daneben gibt es noch den S-Stress von Takane/Young/de Leeuw, der (neben Stress 1) u.a. im Computerprogramm ALSCAL in SPSS verwendet wird:

$$\text{Stressformel nach Takane:} \quad \text{S- Stress} = \sqrt{\frac{\sum_{i < j} (d_{ij}^2 - \hat{d}_{ij}^2)^2}{\sum_{i < j} d_{ij}^4}}$$

¹ Auf dieser Seite wird für die Doppelsumme die verkürzte Schreibweise $\sum_{i < j}$ verwendet. Ausführlich geschrieben wäre das:

$\sum_{i=1}^{n-1} \sum_{j=i+1}^n$, d.h. über alle Elemente der oberen Dreiecksmatrix wird summiert.

Die erhaltenen Stresswerte können anhand der von Kruskal (2005, S. 49 ff.) gelieferten Tabelle wie folgt beurteilt werden:

<i>Anpassungsgüte</i>	<i>Stress 2</i>	<i>Stress 1</i>
vollkommen	$\geq 0,00$	$\geq 0,00$
vorzüglich	$\geq 0,05$	$\geq 0,025$
gut	$\geq 0,10$	$\geq 0,05$
befriedigend	$\geq 0,20$	$\geq 0,1$
schlecht	$\geq 0,40$	$\geq 0,2$

Abbildung 8: Stresswerttabelle

Da in den verschiedenen Computerprogrammen unterschiedliche Stresswerte¹ Verwendung finden, sollte man darauf achten, welche Formel angewandt wird und wie die Stresswerte zu beurteilen sind.

In Abbildung 6 ergibt sich ein Stress 2 von 0,56 (bzw. ein Stress 1 von 0,28). Dies ist ein „schlechter“ Stresswert, der noch verbessert werden muss.

Dies geschieht mit Hilfe des **Gradientenverfahrens**², das festlegt, wie die Startkonfiguration verändert werden muss, um eine „neue“ Konfiguration zu erhalten, die den Stresswert vermindert. Dieses Verfahren wird so häufig durchgeführt, bis der Stresswert für die vorgegebene Dimensionalität (im Beispiel $t=2$) ein Minimum erreicht hat (zum Problem der lokalen Minima siehe Abschnitt 5.3). Die dabei erhaltene Konfiguration nennen wir die Endkonfiguration für die vorgegebene Dimensionenzahl.

Das Gradientenverfahren kann bezüglich eines Objektes i auf Dimension t nach folgender Formel durchgeführt werden (siehe Backhaus et al. 2006, S. 640 ff. und Kappelhoff 2001, S. 27 f.):

$$x_{it}^* = x_{it} + \frac{\alpha}{n-1} \cdot \sum_{j=1}^n \left(1 - \frac{\hat{d}_{ij}}{d_{ij}} \right) \cdot (x_{jt} - x_{it}) \quad (t=1, 2, 3, \dots, r)$$

Die obige Formel entsteht aus der partiellen Ableitung der Stresswertfunktion mit anschließender Nullsetzung sowie einigen Umformungen (zur genaueren Darstellung der Herleitung siehe Borg, Groenen 2005, Kapitel 8 sowie Hartung, Elpelt 2007, S. 410 ff.). Der Parameter α ist die Schrittweite und darf nicht zu groß sein, damit man nicht über das Optimum hinausschießt, aber auch nicht zu klein, da ansonsten der Iterationsprozess zu lange dauert. Kruskal schlägt einen Wert von 0,2 vor. Im Übrigen variieren in den gängigen Algorithmen die Schrittweiten entsprechend dem jeweiligen Stresswert.

¹ Neben dem Stress als Gütekriterium wird noch der RSQ (=squared correlation) herangezogen, der als die quadrierte Korrelation zwischen den Distanzen und den Disparitäten (=Abszissenwert der Regressionskurve) berechnet wird und ein Maß für die lineare Anpassung der Disparitäten an die Distanzen darstellt. Je stärker sich die Punkte in der Grafik an eine Gerade durch den Ursprung anlehnen, desto größer wird R^2 . Diese Kenngröße wird auch als Varianz der Disparitäten interpretiert, die durch die Distanzen in der Konfiguration erklärt wird. In der Praxis gelten Werte größer als 0,9 als akzeptabel (siehe auch Kappelhoff 2001, S. 27 und 37).

² Der Anpassungsprozess verläuft in einigen Computerprogrammen (z.B. ALSCAL im SPSS-Programmpaket) wesentlich komplizierter als das hier geschilderte Gradientenverfahren von Kruskal. Es wird darin ein eigener Stress-minimierender iterativer Prozess durchlaufen, der abbricht sobald eine neue Konfiguration stabil bleibt (siehe Kappelhoff 2001, S. 27).

Nach dieser Formel kann berechnet werden, wie der Koordinatenwert x_{it} von Objekt i auf Dimension t iterativ verbessert werden kann, so dass die Position von Objekt i relativ zu Objekt j verbessert wird.

Der neue Koordinatenwert x_{A2}^* , d.h. derjenige von Objekt A auf Dimension 2 wird in einer ersten Iteration von +0,73 in der Startkonfiguration (siehe Abbildung 6) zunächst auf +0,23 verschoben. In einer zweiten Iteration wird dann der endgültige Wert auf +0,20 in der Endkonfiguration (siehe Abbildung 9) festgesetzt. (Als α wurde 3 gewählt, um sichtbare Veränderungen zu erhalten.)

Mit anderen Worten: Es muss für jedes der vier Objekte auf jeder der zwei Dimensionen der neue Koordinatenwert mittels der obigen Formel berechnet werden. Anschließend wird wieder eine monotone Regressionsfunktion ermittelt und der Stresswert errechnet.

Der Iterationsprozess wird so häufig wiederholt bis

- die Höchstzahl von Iterationen erreicht wurde,
- der Stresswert klein genug ist
- oder sich der Stresswert nicht mehr verbessern lässt.

Für unser Beispiel ergibt sich folgende Endkonfiguration¹:

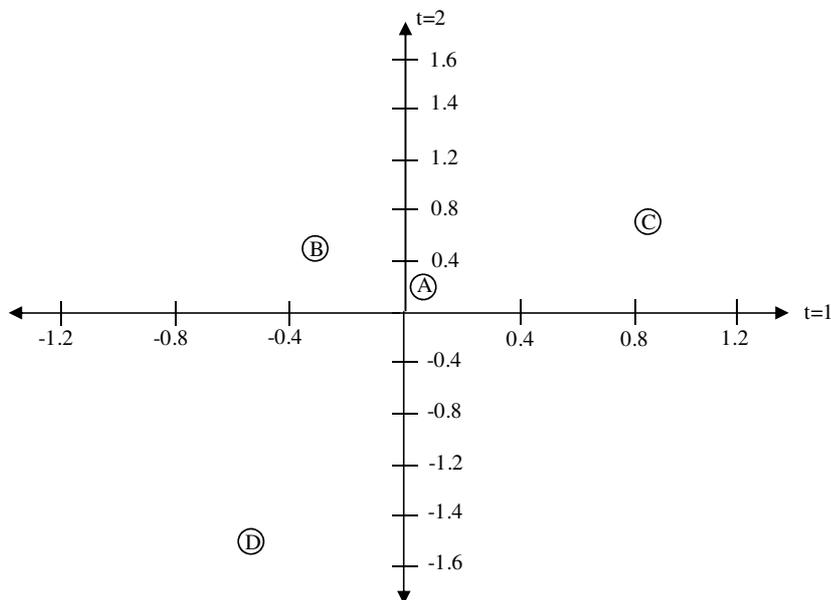


Abbildung 9: Endkonfiguration für $n=4$ Objekte in $t=2$ Dimensionen

Die numerischen Koordinatenwerte der Objekte sind: A (0,07; 0,2), B (-0,35; 0,50), C (0,81; 0,74) und D (-0,52; -1,45). Die Distanzen betragen $AB=0,51$; $AC=0,91$; $AD=1,77$; $BC=1,18$; $BD=1,96$ und $CD=2,56$.

Nach bereits zwei Iterationen liefert das MDS-Computerprogramm eine Endkonfiguration in zwei Dimensionen, deren Stresswert $S=0,00$ beträgt, d.h. es besteht eine vollkommene Übereinstimmung zwischen den Distanzen und den Ähnlichkeiten (in Abbildung 7 werden die Distanzwerte durch \circ -Punkte verdeutlicht). Bei nur vier Objekten in zwei Dimensionen ist dies allerdings nicht verwunderlich.

¹Falls nötig, können die Koordinaten in ein Grafikprogramm (z.B. Corel Draw, Harvard Graphics) übernommen und hübsch aufbereitet werden. Bei der Verwendung der euklidischen Metrik können orthogonale Drehungen sowie Spiegelungen vorgenommen werden, damit auch eine bessere inhaltliche Interpretation möglich ist.

Dieser Algorithmus wird für verschiedene Dimensionalitäten durchgeführt und anschließend wird die Konfiguration mit der kleinsten Dimensionenzahl und „vollkommenem“ Stresswert (d.h. Werte bis 5% bzw. 2,5% bei Stress 1) ausgewählt. (Zur Wahl der Dimensionalität siehe auch Abschnitt 6.4.) Diese Konfiguration nennen wir die Lösungskonfiguration.

Wie ist es nun zu erklären, dass aus ordinalen Eingangsdaten eine metrische Lösungskonfiguration entsteht?

Es wird unterstellt, dass bei einer Lösungskonfiguration eine monotone Beziehung zwischen den Ähnlichkeiten und den Distanzen bestehen soll. Es muss also gelten:

$$\ddot{A}_{ij} < \ddot{A}_{kl} \rightarrow D_{ij} \leq D_{kl}$$

d.h. wenn der Ähnlichkeitsrangwert des Objektpaares ij (\ddot{A}_{ij}) kleiner ist als derjenige des Objektpaares kl (\ddot{A}_{kl}), so soll auch die Distanz des Objektpaares ij (D_{ij}) kleiner (oder gleich) sein als diejenige des Objektpaares kl (D_{kl}). Der Betrag der einzelnen Distanzen wird also durch die Anforderungen der verschiedenen Ungleichungen innerhalb gewisser Grenzen gehalten. Erhöht man die Zahl der Ungleichungen, die annähernd quadratisch mit der Zahl der Objekte wächst, so werden die Intervalle, in denen die Distanzen schwanken können, immer kleiner. Durch die Erhöhung der Zahl der Ungleichungen kann man die Distanzen hinreichend genau bestimmen. Ist die Zahl der Ungleichungen groß genug und die Dimensionenzahl nicht zu groß (siehe auch Abschnitt 6.4), so liefert das nichtmetrische MDS-Verfahren eine Lösungskonfiguration, die metrisches Niveau besitzt, d.h. sie stimmt mit einer Lösungskonfiguration überein, die ein metrisches MDS-Verfahren liefert bzw. sie stimmt mit den „wahren“ Distanzen weitgehend überein. Sehr eindrucksvoll wird dies deutlich, wenn man beispielsweise sämtliche Entfernungen zwischen 10 Städten in der Bundesrepublik Deutschland bestimmt, dann den Entfernungen (insgesamt 45) Rangziffern entsprechend ihrer Größe zuordnet und multidimensional skaliert. Es ergibt sich genau die Lage der Städte wie auf der Landkarte, obgleich nur ordinale Daten verarbeitet wurden. Die ermittelten und die „wahren“ Distanzen stimmen also überein.

Die von uns favorisierte **Unfolding-Version** unterscheidet sich von dem hier beschriebenen Verfahren lediglich dadurch, dass eine Stresswert-Ermittlung für jede Zeile der Datenmatrix erfolgt. Für jede Zeile existiert eine vollständige Rangordnung hinsichtlich der Ähnlichkeit zu einem Ankerstimulus (siehe Abbildung 3). Der Gesamtstresswert ergibt sich dann nach der folgenden Formel¹:

$$S_G = \sqrt{\frac{\sum_{z=1}^m S_z^2}{m}}$$

S_G : Gesamtstresswert
 S_z : Zeilenstresswert
m: Anzahl der Zeilen

Der Gesamtstresswert wird dann für jede vorgegebene Dimensionenzahl minimiert und die Lösungskonfiguration wird ausgesucht.

¹ Wie bereits erwähnt, wird bei der Unfolding-Methode statt dem üblichen Stress-Koeffizienten auf die Stressformel 2 von Kruskal zurückgegriffen (vgl. Borg, Staufenbiel 2007, S. 191 f.), da es ansonsten häufig zu degenerierten Lösungen kommt.

5.2. Verarbeitung der Präferenzdaten

Bei der Verarbeitung der Präferenzdaten können wir zum einen eine externe oder interne Präferenzanalyse anwenden und zum anderen entscheiden, ob das Vektormodell oder das Idealpunktmodell verwandt werden soll.

Bei der **externen Präferenzanalyse** wird eine Ähnlichkeitskonfiguration (direkter oder indirekter Art) vorgegeben. Mit Hilfe der von den Konsumenten angegebenen Präferenzrangfolgen werden dann die Idealpunkte bzw. die Vektoren der Versuchspersonen so in die Konfiguration eingetragen, dass sich die Präferenzrangfolgen wieder ableiten lassen. Ein geeignetes Computerprogramm für die externe Präferenzanalyse ist PREFMAP. (In Backhaus et al. 2006, S. 658 ff., findet sich dazu ein praktisches Beispiel.) Inhaltlich von Bedeutung wäre allerdings, dass die Dimensionen des Raumes die für die Präferenzbildung relevanten Eigenschaften der Objekte repräsentieren. Ob dies bei der vorgegebenen Ähnlichkeitskonfiguration gewährleistet werden kann, ist keineswegs sicher.

Bei der **internen Präferenzanalyse** wird die Konfiguration der Objekte aus den Präferenzurteilen der Konsumenten erstellt und gleichzeitig die Idealpunkte bzw. die Vektoren der Befragungspersonen eingetragen.

Da die Entscheidung z.B. über den Kauf eines Produktes eher von den Ergebnissen der Präferenzbildung statt der Ähnlichkeiten abhängig ist, wollen wir uns im Folgenden mit der internen Präferenzanalyse befassen.

Nun zur Frage, ob das Vektormodell oder das Idealpunktmodell verwendet werden soll?

Beim **Vektormodell** lässt sich die Präferenz der Konsumenten für die Produktmarken mittels Vektoren interpretieren. Die Vektoren gehen durch den Ursprung der Konfiguration. Der Punkt der höchsten Vorziehenswürdigkeit liegt im Unendlichen. Der Pfeil des Vektors liegt in Richtung zunehmender Präferenz. Die Projektion der Objektpunkte auf dem Vektor zeigt die Präferenzrangfolge der Objekte für den entsprechenden Konsumenten. Wenn die Anpassungsgüte vollkommen ist, lassen sich sämtliche von den Konsumenten geäußerten Präferenzrangfolgen wieder ableiten.

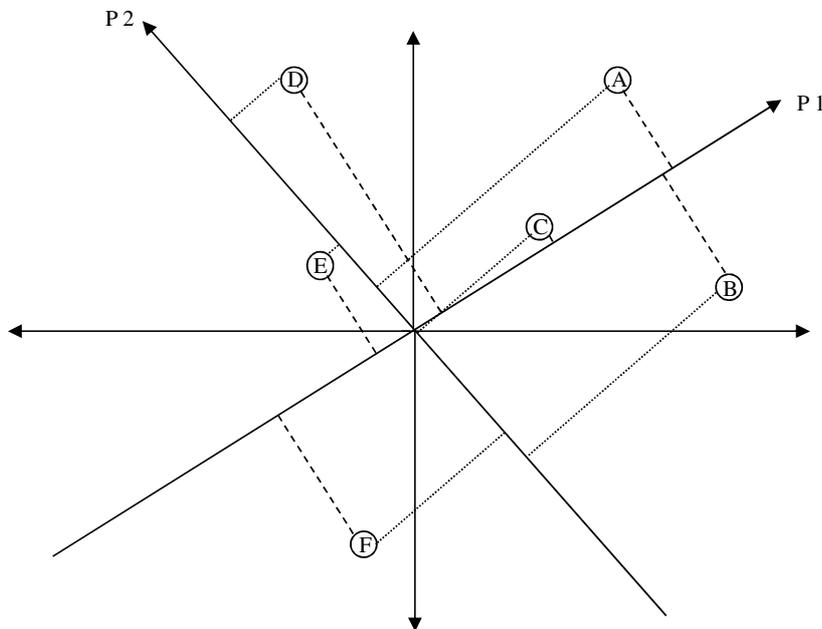


Abbildung 10: Vektormodell, dargestellt für zwei Konsumenten

Präferenzrangfolge bei Person 1: A, B, C, D, E, F; Präferenzrangfolge bei Person 2: D, E, A, C, F, B

Beim **Idealpunktmodell** wird der Punkt der höchsten Vorziehenswürdigkeit für den jeweiligen Konsumenten durch seinen Idealpunkt im mehrdimensionalen Raum bestimmt. Sein Idealpunkt wird dabei so in die Konfiguration gelegt bzw. die Konfiguration so konfiguriert, dass die Distanz zwischen den Objekten und dem Idealpunkt in einer monotonen Beziehung zur Präferenzrangfolge der Objekte steht. Der jeweilige Konsument wird dasjenige Produkt am meisten bevorzugen, das seinem Idealpunkt am nächsten kommt und dasjenige am wenigsten mögen, das von seinem Idealpunkt am weitesten entfernt ist. Im zweidimensionalen Fall sind die Isopräferenzkurven konzentrische Kreise um den Idealpunkt. (Im Prinzip sind auch elliptische Formen denkbar.) Im dreidimensionalen Fall liegen die Punkte gleicher Präferenz auf einer Kugel.

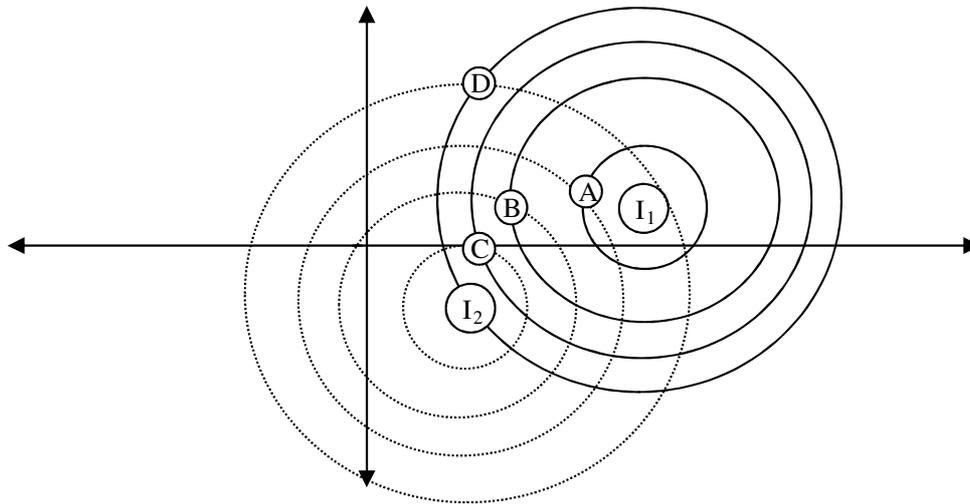


Abbildung 11: Idealpunktmodell, dargestellt für zwei Befragungspersonen

Dabei bedeuten: I_1 = Idealpunkt von Person 1, I_2 = Idealpunkt von Person 2

Präferenzrangfolge für Person 1: A, B, C, D bzw. für Person 2: C, B, A, D

Welchem Verfahren ist der Vorzug zu geben?

Das Vektormodell ist ein Spezialfall des Idealpunktmodells. Es ist nämlich möglich, dass der Idealpunkt im Unendlichen liegt. Dies bedeutet, dass eine Produktmarke dann am meisten bevorzugt wird, wenn sie in Bezug zu wichtigen Produktmerkmalen eine hohe Ausprägung hat. Diese Vorstellung ist jedoch nicht realistisch. So kann beispielsweise die Präferenz gegenüber verschiedenen Arten von Bonbons anhand der Dimension „Grad der Süße“ nicht dadurch abgeleitet werden, dass man annimmt: „Je süßer ein Bonbon, um so eher wird es bevorzugt. Realistisch ist vielmehr, dass ein Bonbon, das eine mittlere Süße besitzt, eher bevorzugt wird als ein extrem süßes Bonbon. Das Idealpunktmodell ist vielseitiger einzusetzen, da es erlaubt, Idealpunkte bei jedem Ausprägungsgrad anzusiedeln. Wir werden uns daher nur noch mit dem Idealpunktmodell befassen.

Wie erfolgt nun die Verarbeitung der Präferenzdaten nach dem Idealpunktmodell?

Die **Unfolding-Version**¹ in den MDS-Computerprogrammen liefert aus den ordinalen Präferenzrangfolgen eine metrische Konfiguration. Die Vorgehensweise entspricht in etwa derjenigen bei den Ähnlichkeitsdaten. Bei der Verarbeitung von Präferenzdaten wird anstatt einem Ankerreiz der Idealpunkt einer Versuchsperson als Bezugspunkt genommen. Die von dem Konsumenten geäußerte Präferenzrangfolge wird in Beziehung zu ihrem Idealpunkt abgeleitet. Diese Präferenzrangfolgen liegen für alle Versuchspersonen vor. Das Verfahren

¹ Dem englischen Begriff „multidimensional unfolding“ entspricht im Deutschen der Begriff „multidimensionale Entfaltung“.

versucht nun die Idealpunkte und die Objektpunkte in einen gemeinsamen Raum vorgegebener Dimensionalität so zu bringen, dass die Rangfolge der Abstände zwischen den Idealpunkten der Versuchspersonen¹ und den Objektpunkten den von den Konsumenten geäußerten Präferenzrangfolgen entspricht.

Um die Güte der Anpassung zu messen, wird wiederum der Stress berechnet und mit Hilfe der Gradientenmethode minimiert. Dieses Verfahren wird auch für mehrere Dimensionen durchgeführt und die angemessene Dimensionalität ausgesucht.

Die mit Hilfe des Verfahrens erzeugte Konfiguration der Objektpunkte ist eine über die Idealpunkte der Versuchspersonen erzeugte Konfiguration (sog. derived configuration). Sie besitzt metrisches Niveau. (Ein Beispiel zur Durchführung des Unfoldingverfahrens findet sich bei Kappelhoff 2001, S. 57 ff.)

Diese so erzeugte Produktmarkenkonfiguration ist von großem Interesse für die diversen Anwendungen im Marketing (siehe auch Kapitel 9).

6. Einzelfragen zur Anwendung

Bei der Anwendung der multidimensionalen Skalierung gibt es mehrere Probleme. Diese beziehen sich auf

- die Anzahl der zu skalierenden Objekte und deren Auswahl,
- die Wahl der Minkowski-Metrik zur Bestimmung der Abstände zwischen den Punkten,
- das Auftreten von lokalen Minima und degenerierten Lösungen
- und schließlich die Bestimmung der Dimensionalität der Lösungskonfiguration.

6.1 Anzahl der Objekte und deren Auswahl

Die minimale **Anzahl** der in die nichtmetrische Ähnlichkeits-MDS einzubeziehenden Objekte wird bei einigen Autoren mit acht angegeben, vielfach werden mindestens zehn empfohlen. Die maximale Anzahl der Objekte wird weniger durch die Verarbeitungskapazität der Computerprogramme bestimmt als durch die für Versuchspersonen zumutbare maximale Belastung, die im allgemeinen bei der Skalierung von etwa 15 Objekten liegt.

Die Entscheidung, wie viele Objekte nun einbezogen werden, hängt von der Anzahl der Dimensionen und von der Interpretationsmöglichkeit der Lösungskonfiguration ab.

Wenn man davon ausgeht, dass nicht nur zwei- sondern auch dreidimensionale Lösungen vorkommen können, so sind im Hinblick auf die Genauigkeit der Lösung mindestens zehn Objekte in die MDS-Analyse einzubeziehen. Die Mindestanzahl von zehn Objekten ist auch für eine sinnvolle Interpretation der Lösungskonfiguration zu fordern. Es gilt im Übrigen auch die Faustregel von Shepard, wonach die Anzahl der Objekte mindestens das Dreifache der Anzahl der Dimensionen sein sollte (siehe auch Abschnitt 6.4).

Eine Erhöhung der Anzahl der Objekte auf 12 oder sogar 15 ist nicht notwendig, da die Genauigkeit der Endkonfiguration sich dadurch nur unwesentlich erhöht. Bei praktischen Marktforschungsuntersuchungen ist die Genauigkeit bei zehn Objekten ausreichend.

¹ Durch Clusteranalysen können die individuellen Idealpunkte zu homogenen Zielgruppen zusammengefasst werden. Dadurch ergeben sich Hinweise für die Marktsegmentierung und die Positionierung bestehender und neuer Produkte. Ein gleiches gilt für das Vektormodell. Hier können benachbarte Vektoren ebenfalls zu Clustern zusammengefasst werden (siehe dazu Backhaus et al. 2006, S. 667). Es können auch Hinweise auf bestehende Marktlücken abgeleitet werden.

Nichtmetrische MDS-Analysen mit nur sechs Objekten sind unseriös, da hierbei keine ausreichende Übereinstimmung zwischen metrischer und nichtmetrischer Lösung besteht.

Bei der Präferenz-MDS sind ebenfalls mindestens zehn Objekte in die Skalierung einzubeziehen.

Im Hinblick auf die **Auswahl der Objekte** ist zu fordern, dass die Objekte nicht in wenige Cluster mit jeweils sehr ähnlichen Stimuli zerfallen dürfen. Für diesen Fall führt die nichtmetrische MDS zu einer degenerierten Lösung (siehe auch Abschnitt 6.3). Die Objekte sollen den Raum gut ausfüllen. Bei der Auswahl genügt es, einige charakteristische Produktmarken auszusuchen, da diese die Endkonfiguration entscheidend bestimmen. Die zusätzlichen Produktmarken dienen nur der Verbesserung der Lösungsgenauigkeit. Dabei sollte jedoch beachtet werden, dass die Produkte den befragten Personen genügend bekannt sind, da ansonsten die Ähnlichkeiten (tw. auch die Präferenzen) nicht valide beurteilt werden können.

Grundsätzlich ist es sinnvoll, dass für das übliche Marketing neben der zu untersuchenden Produktmarke auch die von der Zielgruppe gekauften Konkurrenzprodukte in die Untersuchung einbezogen werden. Möchte man Erkenntnisse für das Marketing gegen Substitutionsprodukte bzw. Produkte aus einer anderen Produktklasse ableiten, so müssen dazu die entsprechenden Substitutionsprodukte bzw. Produkte einer anderen Produktklasse ausgewählt werden. Allerdings darf kein zu großer Unterschied zwischen den Produkten verschiedener Produktklassen bestehen, da dies häufig zu einer entarteten Lösung führt. (Um diese zu vermeiden, gibt es verschiedene Möglichkeiten – siehe dazu Abschnitt 6.3.)

6.2. Wahl der Minkowski-Metrik

Zur Messung des Abstandes zwischen den Objektpunkten in der Konfiguration werden die „Minkowski-Metriken“ verwendet. Sie können wie folgt definiert werden:

$${}_p d_{ij} = \left[\sum_{t=1}^r |x_{it} - x_{jt}|^p \right]^{1/p} \quad 1 \leq p \leq \infty$$

d_{ij} : Abstand zwischen Punkt i und j

x_{it} : Koordinatenwert des Punktes i auf Dimension t

x_{jt} : Koordinatenwert des Punktes j auf Dimension t

r: Anzahl der Dimensionen

p: Parameter der Metrik

Wichtige Werte für p sind p=1 (City-Block-Metrik), p=2 (Euklidische Metrik) und p = ∞ (Supremummetrik). Der Parameter p besitzt eine gewisse Gewichtungseigenschaft. Mit zunehmendem p dominieren die großen Distanzen immer mehr über die kleinen Distanzen.

Bei der **City-Block-Metrik** setzt sich die Gesamtdistanz aus den Distanzen auf jeder Dimension zusammen. Der Name City Block ist angelehnt an ein nach Schachbrettmuster angelegtes Straßensystem (z.B. Manhattan in New York). Will ein Taxifahrer den Abstand zwischen zwei Hotels berechnen, dann kann er nicht die Luftlinie, sondern muss die Summe der zurückgelegten Strecke auf den benutzen waagerechten und senkrechten Straßenabschnitten nehmen. Er kann ja nicht diagonal durch die Häuserblöcke fahren. Bei der **Euklidischen Metrik** wird die Gesamtdistanz im zweidimensionalen Fall nach dem Satz von Py-

thagoras berechnet. Diese euklidische Distanz kann man auch als Luftlinie zwischen zwei Punkten charakterisieren. Auf einem Blatt Papier kann der Abstand mit dem Lineal ausgemessen werden. Bei dieser Metrik beginnen bereits die größeren Distanzen zu dominieren. Bei der **Supremusmetrik** entspricht die Gesamtdistanz der maximalen Distanz auf irgendeiner der Dimensionen. Die Ähnlichkeit eines Objektpaares wird also anhand desjenigen Merkmals bestimmt, bei dem sich die Objekte am meisten unterscheiden.

Im Marketing sind überwiegend die City-Block-Metrik und die Euklidische Metrik von Bedeutung. Dies ist auch verständlich, da die Beurteilung von Produktmarken meist von mehreren Produktmerkmalen abhängig ist und nicht nur von einem einzigen Merkmal wie bei der Supremusmetrik. Allerdings wurde in der Urteilspsychologie festgestellt, dass bei schwierigen Ähnlichkeits- bzw. Präferenzbeurteilungen und wenig Zeit für die Entscheidung, die Versuchspersonen bei ihren Bewertungen dazu neigen, nur das Merkmal mit der größten Differenz heranzuziehen ($p \rightarrow \infty$), während bei leichten Urteilen alle relevanten Merkmale ungefähr das gleiche Gewicht erhalten ($p \rightarrow 1$)

Bei der Unfolding-Version ist nur die Anwendung der Euklidischen Metrik ($p=2$) üblich. Weiterhin erleichtert die Euklidische Metrik die Interpretation der Lösungskonfiguration mittels Merkmalsvektoren bzw. ermöglicht diese überhaupt erst (siehe auch Kapitel 7). Die euklidische Metrik hat darüber hinaus den Vorteil, dass die Konfiguration um das Koordinatenkreuz orthogonal gedreht oder an den Achsen gespiegelt werden kann, ohne dass sich die Distanzen zwischen den Objekten ändern. Es kann verschoben, aber auch proportional vergrößert und verkleinert werden, allerdings ist ein Stauchen und Strecken nicht zulässig, da sich die Entfernungen dann verändern. Das Computerprogramm ALSCAL erlaubt daher auch nur die Verwendung der euklidischen Metrik (ein Spezialfall stellt dabei INDSCAL dar, das die euklidischen Distanzen mit einem individuellen Gewichtungsfaktor für jede Dimension versieht – siehe auch Kappelhoff 2001, S. 16 f. und Abschnitt 3 bzw. 8).

In Untersuchungen zur mehrdimensionalen Messung, in denen unterschiedliche Metrikparameter verglichen wurden, zeigte sich eine leichte Überlegenheit der City-Block-Metrik gegenüber der Euklidischen Metrik. Da der Effekt aber klein gewesen ist, ist die Validität des Verfahrens nicht in Frage gestellt.

6.3. Auftreten lokaler Minima und degenerierter Lösungen

Mit Hilfe des Gradientenverfahrens (siehe Abschnitt 5.1) wird der Stresswert, ausgehend von einem Anfangsstresswert bei der Startkonfiguration, zunehmend verringert, bis er ein Minimum erreicht. Bei der Anwendung des Gradientenverfahrens taucht jedoch das Problem auf, dass u.U. nur ein **lokales Minimum**¹ und nicht das absolute Minimum gefunden wird. Man kann sich das Problem anhand der Abbildung 12 verdeutlichen.

Der Anfangsstresswert liegt bei Z. Mit Hilfe des Gradientenverfahrens wird nun beispielsweise bestimmt, dass der Koordinatenwert x_{it} zu verringern ist. Die Größe der Veränderung des Koordinatenwertes kann mit Hilfe des Gradientenverfahrens nicht bestimmt werden. Sind kleine Schrittweiten vorgegeben, d.h. wird der Koordinatenwert jeweils nur wenig geändert, so wird der Stresswert nur das lokale Minimum B und nicht das absolute Minimum A erreichen.

¹ Etliche MDS-Computerprogramme können das globale Minimum nicht zuverlässig finden, sondern bleiben im lokalen Minimum hängen. Einige moderne MDS-Programme mit verändertem Algorithmus können jedoch das globale Minimum bezogen auf die vorgegebene Dimensionalität mit hoher Sicherheit finden (siehe auch Borg, Staufenbiel 2007, S. 167).

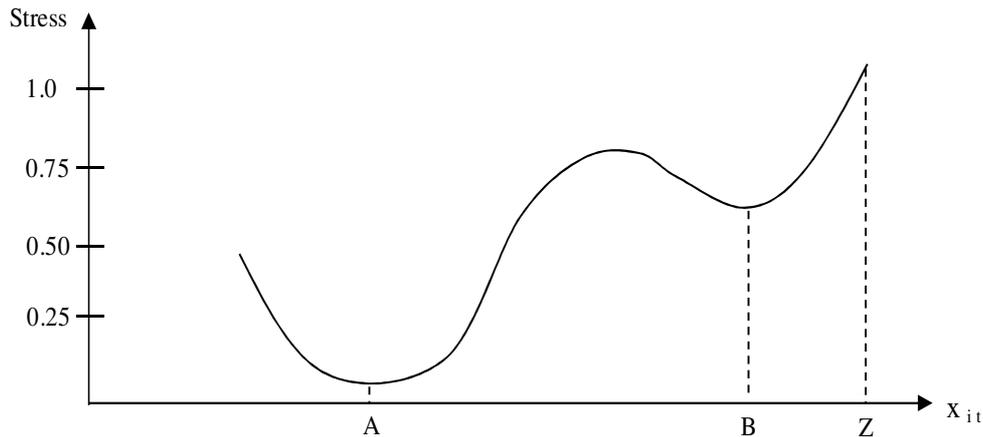


Abbildung 12: Zusammenhang zwischen Stress S und Koordinatenwert x_{it} des Punktes x_i auf der Dimension t

Man hat üblicherweise nun zwei Möglichkeiten, lokale Minima zu vermeiden:

1. Es werden immer wieder andere Zufallsstartkonfigurationen eingegeben. Ergeben mehrere Computerläufe immer wieder dieselben Stresswerte, so ist anzunehmen, dass wir bei vorgegebener Dimensionalität ein absolutes Minimum erreicht haben. Dieses Verfahren ist leider zeitaufwendig.
2. Man gibt „rationale“ Startkonfigurationen ein, die bereits Werte nahe dem absoluten Minimum liefern. Diese rationalen Startkonfigurationen sind bei der Ähnlichkeits-MDS dadurch zu finden, dass mit der metrischen Version eines MDS-Computerprogramms zuerst eine Konfiguration errechnet wird und diese dann eingegeben wird. Bei einigen Computerprogrammen besteht auch die Möglichkeit, eine Startkonfiguration aus der Faktorenmatrix einer Hauptachsenlösung zu bilden. Bei der Präferenz-MDS könnte die Endkonfiguration der Ähnlichkeits-MDS als Startkonfiguration für die Objekte verwendet werden.

Am einfachsten ist die erste Möglichkeit, d.h. es können bei vorgegebener Dimensionalität mehrere Computerläufe mit jeweils anderen Zufallsstartkonfigurationen durchgeführt werden. Die rationalen Startkonfigurationen gewährleisten nämlich nicht das Erreichen des absoluten Minimums, hingegen führt die mehrfache Verwendung von Zufallsstartkonfigurationen meist zum absoluten Minimum.

Nun noch zum Problem der **degenerierten Lösung**:

Eine degenerierte Lösung ist daran zu erkennen, dass der Stresswert der Lösungskonfiguration für etwa 10 Objekte bei Null bzw. fast Null liegt. Die Konfiguration mit einer geringeren Dimensionenzahl als die Lösungskonfiguration hat dagegen einen Stresswert, der größer als 5% ist. Man spricht von einer degenerierten Lösung, wenn die in den Daten enthaltenen Strukturen nur sehr grob durch die Konfiguration wiedergegeben werden.

Eine degenerierte Lösung entsteht dann, wenn die Objekte in nur wenige Cluster mit jeweils ähnlichen Stimuli zerfallen. Es wird dadurch eine fast perfekte Monotonie erzielt, da die Abstände zwischen den Clustern immer größer sind als innerhalb der Cluster. Durch geschickte Auswahl der Objekte, die den Raum möglichst gut ausfüllen sollen, kann dies vermieden werden. Auf eine metrische MDS auszuweichen, ist nicht zulässig, wenn die Ausgangsdaten kein Intervallskalenniveau besitzen. (Bei einer metrischen MDS werden jedoch degenerierte Lösungen vermieden - siehe dazu Borg, Staufenbiel 2007, S. 165). Es besteht aber die Möglichkeit, den Iterationsprozess bei einem genügend kleinen Stresswert

abzubrechen. Dann wird zumindest vermieden, dass die Objekte in der Endkonfiguration in mehrere eng umgrenzte Cluster zerfallen oder mehrere Objekte sogar nur einen gemeinsamen Koordinatenwert haben.

Einige Computerprogramme (z.B. ALSCAL) greifen auf ein komplexeres Stressmaß zurück, bei dem die Gefahr entarteter Lösungen stark verringert wird (siehe Kappelhoff 2001, S. 26).

6.4 Bestimmung der Dimensionalität

Kriterien zur Bestimmung der Dimensionalität sind insbesondere die Anpassungsgüte (charakterisiert durch den Stresswert) und die statistische Gültigkeit.

Im Hinblick auf die **Anpassungsgüte** ist diejenige Dimensionalität zu wählen, bei der der Stress genügend klein ist.

Der Zusammenhang zwischen Stress und Dimensionalität zeigt Abbildung 13.

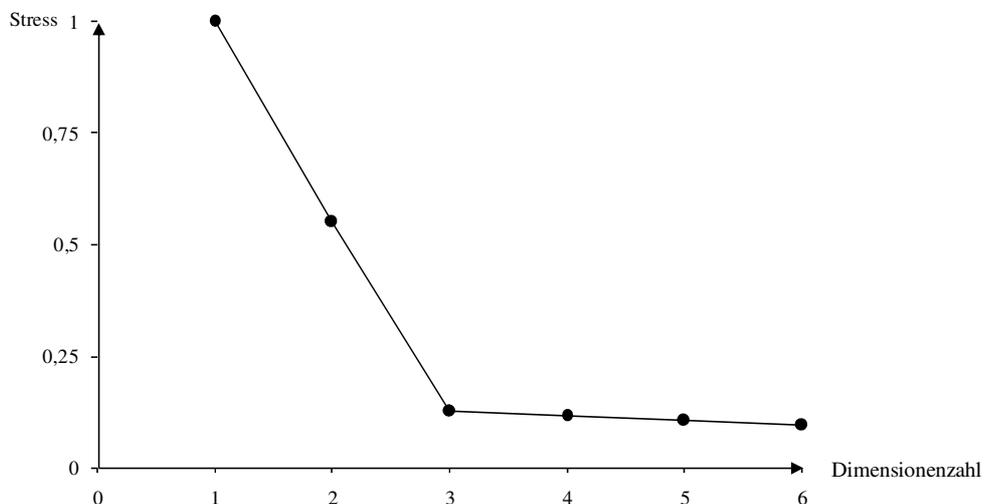


Abbildung 13: Zusammenhang zwischen Stress und Dimensionenzahl

Mit zunehmender Dimensionalität fällt der Stresswert ab. Häufig wird behauptet, dass sich in der Stresswertkurve ein „Knick“ („elbow“) ergibt, d.h. trotz Erhöhung der Dimensionenzahl fällt der Stresswert nicht mehr erheblich ab. Dann soll die dieser Stelle zugeordnete Dimensionenzahl gewählt werden (im Beispiel $t=3$). Entscheidend ist jedoch der Stresswert, der für die Lösungskonfiguration höchstens 5% (bzw. 2,5% bei Stress 1) betragen sollte.

Entsprechend dem Kriterium der **statistischen Gültigkeit** darf bei der Ähnlichkeits-MDS keine zu hohe Dimensionenzahl gewählt werden. Es besteht die Gefahr, dass es sich bei der Lösungskonfiguration nicht um die „wahre“ Konfiguration handelt, d.h. der durch dieses Verfahren erzielte metrische Effekt geht verloren. Im Allgemeinen gilt die Faustregel, dass der Quotient¹

$$\frac{\text{Anzahl der Objekte } n}{\text{Anzahl der Dimensionen } t} \geq 4 \text{ sein soll.}$$

¹ Backhaus et al. (2006, S. 645 f.) befassen sich eingehender mit dem Datenverdichtungskoeffizienten Q, der als Quotient der Zahl der Ähnlichkeiten und der Anzahl der Koordinaten berechnet wird und größer als 2 sein sollte. Die Ergebnisse stimmen in etwa mit den oben beschriebenen Quotienten überein.

Daneben gilt noch die allgemeine Einschränkung: $t = n-1$. Diese gilt deshalb, weil sich n Punkte trivialerweise immer im $(n-1)$ -dimensionalen Raum darstellen lassen.

Nur diese Einschränkung gilt für die Präferenz-MDS, sofern genügend Versuchspersonen in die Untersuchung einbezogen werden. Wenn zehn Objekte und 30 Versuchspersonen multidimensional skaliert werden, dann ist eine Lösungskonfiguration noch mit sechs Dimensionen zulässig.

In einer Untersuchung von Quack (1980, S. 62) wurde herausgefunden, dass bei einer Präferenz-MDS die Stresswerte „vollkommen“, d.h. kleiner als 5% (bzw. 2,5% bei Stress 1), sein sollten, da bereits bei einem Stresswert über 7% (bzw. 3,5%) keine signifikante Übereinstimmung mehr zwischen den vorhergesagten und „wahren“ Werten (im speziellen Fall Einstellungsrelevanz von Produktmerkmalen bzw. Erinnerung an die kaufrelevanten Merkmale) gegeben war. Insofern kommt es nicht auf niedrig dimensionierte Lösungen an, sondern „vollkommene“ Stresswerte sind anzustreben.

Wünschenswert sind natürlich zweidimensionale Lösungen, was die grafische Darstellung und auch die Interpretierbarkeit erheblich erleichtert, aber auch dreidimensionale Lösungen sind noch verwertbar. Lösungen mit mehr als drei Dimensionen werden nicht angestrebt. Falls jedoch höherdimensionale Lösungskonfigurationen eine bessere Interpretierbarkeit liefern, sollte auf diese zurückgegriffen werden (vgl. Borg, Staufenbiel 2007, 179 f.)

7. Interpretation der Konfiguration

Der abschließende Schritt der MDS-Analyse ist die Interpretation der Lösungskonfiguration, die die metrische Repräsentation der skalierten Ähnlichkeits- bzw. Präferenzbeziehungen darstellt. Es soll dadurch ermittelt werden, welche Objektmerkmale die Ähnlichkeits- bzw. Präferenzbeziehungen der Objekte zueinander entscheidend bestimmen. Die signifikanten Merkmale kann man dann als bedeutsam für den Kauf eines Produktes bzw. genauer gesagt als einstellungsrelevant bezeichnen.

Bei der Interpretation der Objektkonfiguration unterscheiden wir zwischen interner und externer Analyse.

Bei der **internen Analyse** wird die Konfiguration ohne Heranziehung sonstiger Daten interpretiert. Es gibt dabei die Möglichkeit, die Achsen orthogonal so zu rotieren, bis sie nach Meinung des Untersuchenden zu interpretieren sind. (Eine Rotation ist jedoch nur bei Verwendung der euklidischen Metrik möglich.) Oder man sucht nach Clustern, Kreisen bzw. Ellipsen, Regionen, Sektoren oder anderen geometrischen Strukturen (vgl. genauer dazu Borg, Staufenbiel 2007 S. 170 ff. und Borg, Groenen 2005, Kapitel 5 über die Facettentheorie), die in bereits vorhandene (theoretische) Konzepte hineinpassen. Eine auffallende geometrische Struktur ist im zweidimensionalen Fall eine kreisförmige Struktur, wie sie bspw. der Farbkreis darstellt. Die interne Analyse ist jedoch sehr subjektiv beeinflusst. Sie sollte daher zur Interpretation der Konfiguration nicht herangezogen werden, da eine standardisierte Methode wünschenswert ist.

Bei der **externen Analyse** zieht man zur Interpretation extern erhobene Daten hinzu. Dies kann geschehen mittels dem Einbezug von Merkmalsidealpunkten oder durch das Einbeziehen von Merkmalsvektoren.

Bei der Interpretation mittels *Merkmalsidealpunkten* werden diese so in die Konfiguration gelegt, dass die Abstände zu den einzelnen Objektpunkten mit den Rangfolgen der Objekte bezüglich der jeweiligen Merkmale optimal übereinstimmen, d.h. Objekte, die eine „gewünschte“ Merkmalsausprägung haben, sollen dem Merkmalsidealpunkt näher liegen als Objekte, die eine „gering gewünschte“ Merkmalsausprägung haben.

Größere Bedeutung hat die Interpretation mittels *Merkmalsvektoren*. Diese Methode wird auch als „Property Fitting“ bezeichnet. Die Vektoren kann man dadurch erheben, dass die Ausprägung der Objekte auf einer Merkmalsdimension erhoben wird. Bspw. kann man zehn Füllhalter (=Objekte) auf der Merkmalsdimension „liegt gut in der Hand“ anhand einer Ratingskala von sehr gut (=5) bis sehr schlecht (=1) beurteilen lassen. Das Ergebnis der Messungen stellen dann die Merkmalsausprägungen dar. In das Programm werden die Mittelwerte der Eigenschaftsbeurteilungen eingegeben. Die Merkmalsvektoren werden dann so in die Konfiguration gelegt und gedreht, dass die Projektion der Objektpunkte auf dem Merkmalsvektor mit den extern erhobenen Merkmalswerten höchstmöglich korreliert.

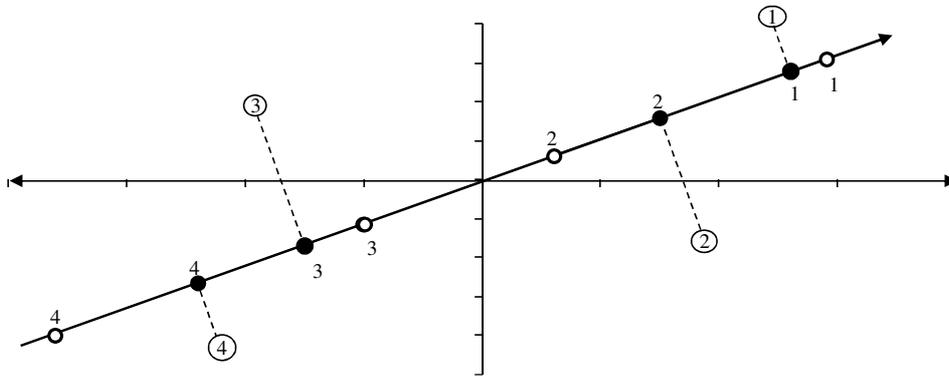


Abbildung 14: Lage eines Merkmalvektors in einer Konfiguration mit vier Objekten

- : Projektion der Objektpunkte i auf den Merkmalsvektor
- : gemessener Merkmalswert der Objekte i auf dem Merkmalsvektor

Die Korrelation kann linear oder nichtlinear sein bzw. sich lediglich an ordinalen Beziehungen orientieren. Ein häufig verwandtes Computerprogramm zur Interpretation der Konfiguration mittels Merkmalsvektoren ist PROFIT (vgl. auch Kapitel 8). Darin steht nur eine lineare und nichtlineare Korrelation zur Verfügung. Üblicherweise liefert die lineare Korrelation vernünftige Ergebnisse - sie ist auch den Daten meist angemessen; es sei denn, man weiß aus eigener Erfahrung, dass nichtlineare Zusammenhänge vorliegen. Es können beliebig viele Merkmalsvektoren in die Interpretation einbezogen werden. Allerdings „streiken“ die befragten Personen, wenn sie die Objekte auf mehr als 15 Merkmalen beurteilen sollen.

Diejenigen Faktoren, die hohe (signifikante) Korrelationen aufweisen, werden zur Interpretation der Konfiguration herangezogen. Da diese Merkmalsvektoren nicht voneinander unabhängig sind, können durch die Faktorenanalyse noch die unabhängigen Faktoren herausgefunden werden.

Die Interpretation mittels Merkmalsvektoren kann nur bei Verwendung der euklidischen Metrik verwandt werden, da nur bei dieser Metrik eine Rotation der Achsen möglich ist, ohne dass sich die Abstände zwischen den Punkten verändern. Die Verwendung der euklidischen Metrik ist daher eine Voraussetzung für den Einsatz von PROFIT.

Die Interpretation mittels Merkmalsvektoren kann sowohl bei der Ähnlichkeits- als auch bei der Präferenzkonfiguration verwandt werden.

Bei der Ähnlichkeitskonfiguration ist dies unmittelbar einsichtig, da die mit Hilfe der MDS erstellte Markenkonfiguration metrischen Charakter besitzt. Bei der Analyse der Präferenzdaten wird über die Idealpunkte der Versuchspersonen eine abgeleitete Produktmarkenkonfiguration erstellt. Auch diese Konfiguration hat metrischen Charakter und es können auch Vergleiche zwischen den Produktmarken erfolgen. Daher kann das PROFIT-Verfahren auch bei der Präferenzkonfiguration eingesetzt werden.

An dieser Stelle bleibt noch zu erwähnen, dass die Merkmale möglichst kauf- bzw. einstellungsrelevant sein sollten, da sie ansonsten zur Interpretation der Konfiguration nicht geeignet sind. Im Vorfeld benötigt man daher Merkmale, die sich später hoffentlich als einstellungsrelevant erweisen. Es gibt eine Reihe von Verfahren, um eine Vielzahl von Merkmalen zu generieren. Eine bewährte Methode ist die Gittertechnik (Repertory Grid). Dabei werden den Befragten Dreiergruppen von Produkten vorgelegt und sie sollen ein Merkmal angeben, das zwei Marken einander ähnlich und von der dritten verschieden erscheinen lässt (genauer dazu Trommsdorff 2004, S. 187). Darüber hinaus ist noch anzumerken, dass die Merkmale nicht nur denotativ, sondern auch konnotativ sein können. Dies bedeutet, dass die Eigenschaften nicht unmittelbar produktbezogen sein müssen (z.B. Benzinverbrauch, Höchstgeschwindigkeit bei einem Auto), sondern auch psychologischer Natur (z.B. das Auto ist elegant, sexy, prestigeträchtig) sein können. Gerade die einstellungsrelevanten konnotativen Merkmale liefern viele Ansatzpunkte für eine wirksame Werbung.

8. Computer-Programme für MDS

Etliche Computerprogramme wurden bereits in diesem Artikel angesprochen. Nachfolgend sollen die wichtigsten charakterisiert sowie einige neuere Entwicklungen kurz vorgestellt werden, die jedoch nur für Experten in der Marketingpraxis geeignet sind.

Wie bereits in Kapitel 3 und Abbildung 2 veranschaulicht, können die diversen MDS-Verfahren nach folgenden Gesichtspunkten eingeteilt werden:

- Nach dem Skalenniveau können metrische und nichtmetrische Verfahren unterschieden werden.
- Nach dem Inhalt der Ausgangsdaten werden Ähnlichkeiten oder Präferenzen erhoben. Wie besprochen, bevorzugen wir die Ankerreizmethode bei der Erhebung der Ähnlichkeiten. Daneben gibt es noch die Methode der vollständigen Rangordnung. Darüber hinaus wird bei der Präferenz-MDS zwischen der externen und internen Präferenzskalierung unterschieden. Bei der Verwendung der Ankerreizmethode und der internen Präferenzskalierung wird die Unfolding-Methode eingesetzt.
- Nach dem Grad der Aggregation wird in aggregierende und nichtaggregierende Verfahren differenziert. Bei den nichtaggregierenden Verfahren haben wir die replizierte und die gewichtete Version unterschieden.

Entsprechend dieser Einteilung wird in Abbildung 15 ein kurzer Überblick über gebräuchliche Computerprogramme sowie einige Weiterentwicklungen gegeben. Wer sich tiefergehend informieren möchte, dem sei Borg, Groenen (2005) empfohlen.

Die bekanntesten Softwarepakete, in denen die Multidimensionale Skalierung enthalten ist, sind SPSS und SAS (=Statistical Analysis System). Ein weiteres für viele Statistikprozeduren geeignetes Softwarepaket ist BMDP (= Biomedical Computer Programms, P-Series), das allerdings kein MDS enthält.

SPSS (= Statistical Package for Social Sciences) ist ein sehr bekanntes Statistikprogramm, das die gängigen statistischen Verfahren, auch viele multivariate, umfasst. Zusätzlich zum Software-Programm gibt es Handbücher (z.B. SPSS Inc. 2007) sowie Anwendungsbücher (z.B. Brosius 2008 und Bühl 2008), die auch Erläuterungen und Anwendungsbeispiele zur MDS beinhalten.

Nun noch vertiefend zu einzelnen MDS-Programmen:

ALSCAL (alternating least square scaling): Die verschiedenen Methoden zur metrischen/nichtmetrischen, zur gewichteten/ungewichteten sowie zur replizierten MDS können von ALSCAL bearbeitet werden, das Bestandteil in SPSS und SAS ist. Die Proximitäten kön-

nen nominal, ordinal oder metrisch und die Matrizen symmetrisch, asymmetrisch oder rechteckig sein.

Programm	Charakterisierung	Fundstelle
ALSCAL	Umfangreiches Programm zur Verarbeitung von metrischen u. nichtmetrischen Ähnlichkeits- und Präferenzdaten, incl. der replizierten und gewichteten Variante.	SPSS, SAS
PROFIT	Verfahren zur Einbettung von Eigenschaftsvektoren in den Wahrnehmungsraum zwecks Interpretationshilfe.	z.B. in ALSCAL, NEWMDSX
INDSCAL	Mehrwege-MDS, insbes. für die gewichtete MDS	z.B. in ALSCAL, NEWMDSX sowie unter www.netlib.org/mds/
PREFMAP	Die Präferenzen werden als Idealpunkte oder Vektoren in eine vorgegebene Konfiguration eingebettet (externe Präferenzanalyse).	z.B. in NEWMDSX
KYST	Breit einsetzbares MDS-Computerprogramm, u.a. für eine konfirmatorische MDS geeignet.	www.netlib.org/mds/
PERMAP	Zur Durchführung einer interaktiven MDS.	als Freeware aus dem Internet: www.ucs.louisiana.edu/~rbh8900
ML-MDS	Maximum Likelihood MDS	z.B. MULTISCALE; zu beziehen über James O. Ramsay, Mc Gill University, Montreal

Abbildung 15: Überblick zu MDS-Computerprogrammen (vgl. auch Borg, Groenen 2005, S. 543 ff.)

Es können auch einzelne Einträge in den Matrizen fehlen. (Eine Weiterentwicklung stellt der SMACOF-Algorithmus dar, der noch effizienter zur Lösung findet – siehe auch Borg, Groenen 2005, S. 187 ff.) Der Vorteil von ALSCAL ist, dass der Benutzer im Vergleich zu älteren Programmen sofort eine High-Resolution-Darstellung der ermittelten Konfigurationen erhält. Anschauliche Beispiele für die Vorgehensweise bei den verschiedenen Arten der MDS, inklusive der Ankerreizmethode sowie der replizierten und gewichteten Variante, finden sich in Kappelhoff (2001, S. 29 ff.). Auch die Anwendung der Unfolding-Methode sowie Möglichkeiten der sinnvollen Aggregation finden sich bei Kappelhoff (2001, S. 60 ff.). Darüber hinaus sind die oben erwähnten Anwendungs- und Handbücher sehr hilfreich.

PROFIT: Bereits ausreichend erläutert in Kapitel 7.

INDSCAL (Individual Differences Scaling): Siehe dazu Kapitel 3, Abschnitt über „nicht-aggregierende Verfahren“.

PREFMAP: Dieses Programm ist für eine externe Präferenzanalyse gedacht, d.h. eine Konfiguration ist vorgegeben und das Programm bettet die Präferenzen, dargestellt als Vektoren oder Idealpunkte, in die Konfiguration so ein, dass sich die Bevorzugungen wieder bestmöglich herleiten lassen. Das Programm verarbeitet metrische und nichtmetrische Daten. Man erhält auch Gewichte für die Dimensionen. Ein Beispiel zur Anwendung findet sich in Backhaus et al. (2006, 658 ff.). Er empfiehlt auch, von den 4 Phasen nur die Phase 3 (Idealpunktmodell) und 4 (kreisförmiges Vektormodell) anzuwenden.

POLYCON: Nur intervallskalierte Ähnlichkeitsdaten können verarbeitet werden, auch diejenigen, die mittels der Ankerreizmethode erhoben wurden. Auch eine Wiederholungs-

MDS kann verwendet werden. Ein Beispiel zur Anwendung findet sich bei Backhaus et al. (2006, S. 648 ff.).

Weiterentwicklung der Multidimensionalen Skalierung

Nachfolgend noch zwei (von etlichen anderen) Erweiterungen zur MDS sowie die zugehörigen Computerprogramme (siehe dazu auch Carroll, Green 1997).

Konfirmatorische MDS: Man kann neben der Minimierung des Stress und der Wahl der Funktion noch weitere Forderungen an die Lösung stellen, z.B. dass die Punkte genau rechtwinklig zueinander liegen, einen Kreis oder eine Art Gitter bilden. (Ausgangspunkt für diese geometrischen Strukturen kann die Facettentheorie sein – genauer dazu Borg, Groenen 2005, Kapitel 5.) Man fragt also von vornherein, wie gut sich die Daten im Rahmen einer vorgegebenen Theorie darstellen lassen. Dazu werden Computerprogramme (z.B. KYST) verwendet, die es erlauben, der MDS-Lösung verschiedenartige Nebenbedingungen aufzuzwingen (siehe auch Borg, Staufenbiel 2007, S. 180 ff.). Eine Erweiterung stellt die *interaktive MDS* dar, bei der zusätzlich berechnet werden kann, ob die Verschiebung einzelner Punkte in der Lösungskonfiguration, die nicht gut zu einer Interpretation passen, den Stresswert stark oder nur wenig erhöhen. Hier kann PERMAP verwandt werden, das als Freeware-Programm aus dem Internet heruntergeladen werden kann. Darüber hinaus gibt es noch etliche Erweiterungsmöglichkeiten bei der konfirmatorischen MDS, die jedoch eine intensive theoretische und rechentechnische Einarbeitung verlangen. Weitere Informationen finden sich bei Borg, Groenen (2005, z.B. Kapitel 10).

Maximum-Likelihood-MDS: Diese wichtige Weiterentwicklung ermöglicht nicht nur deskriptive, sondern auch inferenzstatistische Schlüsse. Durch Signifikanztests können die geeignete Dimensionalität, das geeignete MDS-Modell sowie das geeignete Fehlermodell bestimmt werden. (Voraussetzung für die Anwendbarkeit ist jedoch die Normalverteilung der Fehlerkomponente.) Geeignete Computerprogramme sind MULTISCALE, MAXSCAL und PROSCAL, die jedoch nur als Einzelprogramme von unterschiedlichen Forschern erhältlich sind. Tiefgehende Informationen sind Bijmolt, Wedel (1999) zu entnehmen.

Wie bereits erwähnt, verlangt die Anwendung der Weiterentwicklungen einen beträchtlichen Zeitaufwand für das Einarbeiten in die mathematischen Grundlagen sowie die rechentechnische Durchführbarkeit. Sie können daher nur für Eingeweihte in der Marketingpraxis empfohlen werden.

9. Kurzer Ausblick zum Einsatz der MDS im Marketing

Eine ausführliche Darstellung zum praxisnahen Einsatz der MDS im nationalen und internationalen Marketing soll dem Teil 2 vorbehalten bleiben. An dieser Stelle soll jedoch auf die Einsatzmöglichkeiten der MDS im Marketing kurz eingegangen werden.

Das Ergebnis einer multidimensionalen Skalierung ist z.B. die folgende Lösungskonfiguration für das Produkt „Füllhalter“, wie sie schematisch in Abbildung 16 dargestellt ist.

Welche Erkenntnisse kann man aus dem Ergebnis einer solchen multidimensionalen Skalierung gewinnen?

- Das eigene Produkte und die Konkurrenzprodukte können in einem *Wahrnehmungsraum* mit drei Dimensionen dargestellt werden. Man erhält eine grafische Darstellung der *realen Lage der Produkte* bezüglich der psychischen Ähnlichkeit (bzw. der Präferenznähe) der Produkte zueinander. Diesen Wahrnehmungsraum kann man auch als *Marken- bzw. Imagerraum* charakterisieren. Wurden mehrere Produkte in die Untersuchung einbezogen, dann sind oftmals *Produktcluster* zu erkennen, d.h. Produkte, die sehr nahe beieinander liegen, können in homogene Produktkategorien eingeteilt werden.

- Es könnte daraus auch die Erkenntnis abgeleitet werden, dass das eigene Produkt zwar den Bedürfnissen einer Zielgruppe entspricht, aber denjenigen anderer Zielgruppen nicht entspricht. Dies wäre der Anlass über eine *Produktdifferenzierung* bzw. eine *Marktsegmentierung* sowie über *neue Produkte* nachzudenken.
- Es kann auch über die *Repositionierung* des eigenen Produktes bzw. über die Zielvorstellungen zur *Neupositionierung* eines neu zu entwickelnden Produktes nachgedacht werden (siehe dazu auch Trommsdorff 2008).
- Selbstverständlich können bei wiederholter Durchführung der MDS-Analysen die *Wirkungen von Marketingmaßnahmen* sowie die *Änderungen im marketingbezogenen Umfeld* erkannt werden.
- Für die tägliche Marketingpraxis und auch im Hinblick auf die oben angesprochenen strategischen Alternativen gibt es eine Fülle von *Marketingmaßnahmen*, um die eigene Marke attraktiver zu machen, d.h. den Abstand zwischen dem Realpunkt des eigenen Produktes und einem Idealpunkt zu verringern (siehe auch Kroeber-Riel, Weinberg 2003, S. 212 ff.).
 - *Veränderung der Realpunkte*: Die Position der eigenen Marke kann in Richtung einer Idealmarke bzw. des Idealpunktes einer Zielgruppe verändert werden. Dies kann durch produktpolitische Maßnahmen geschehen, indem bspw. die „Qualität der Feder“ verbessert wird oder durch Werbemaßnahmen, indem die Wahrnehmung der „Eleganz“ in Richtung Idealpunkt verschoben wird. Es besteht auch die Möglichkeit, die Distanz der Konkurrenzmarke K zum Idealpunkt zu vergrößern, indem bspw. durch Werbung auf Nachteile der Konkurrenzmarke hingewiesen wird. Im obigen Beispiel etwa auf mangelnde Eleganz. Diese Strategie wird jedoch teilweise durch gesetzliche Vorschriften blockiert; außerdem ist diese Strategie schwierig in der Anwendung.
 - *Veränderung des bzw. der Idealpunkte*: Dies kann nur durch Marktkommunikation erreicht werden. In unserem Beispiel, indem die Idealvorstellung in Richtung „mehr Eleganz“ und „weniger Qualität der Feder“ beeinflusst wird. Idealvorstellungen sind jedoch schwierig zu beeinflussen. Dies zeigen empirische Untersuchungen, die nur einen geringen Einfluss der Werbung auf die Idealproduktvorstellungen feststellen konnten.
 - *Veränderung der Menge einstellungs- bzw. kaufrelevanter Merkmale*: Dies kann einerseits dadurch erfolgen, dass ein bisher kaufrelevantes Merkmal seine Kaufrelevanz verliert und andererseits ein nicht kaufrelevantes Merkmal nun für den Kauf bedeutsam wird. In unserem Beispiel kann durch gezielte Werbung das Merkmal „Qualität der Feder“ seine Einstellungsrelevanz verlieren und das Merkmal „liegt gut in der Hand“ einstellungsrelevant werden. Dies würde bedeuten, dass die eigene Marke dann näher am Idealpunkt I_1 liegt als die Konkurrenzmarke. Es besteht auch die Möglichkeit, dass sich durch eine Veränderung des Umfelds die Einstellungsrelevanz der Produktmerkmale verändert, beispielsweise durch Änderung der Werte (Schönheit geht vor Qualität) oder durch Einführung neuer Marken mit bestimmten Vorzügen (z.B. Füllhalter mit besonderen Griffschalen). Dadurch können andere Dimensionen kaufrelevant werden. Aber diese Veränderungen sind ebenfalls mit der MDS zu erkennen.

Zusammenfassend können wir festhalten, dass mit Hilfe der MDS eine Fülle von Erkenntnissen gewonnen und daraus eine Reihe von Marketingmaßnahmen abgeleitet werden können. Auf die Anwendung der MDS auf konkrete marketingbezogene Fragestellungen werden wir im zweiten Teil dieses Artikels vertiefend eingehen, insbesondere auch den internationalen Aspekt eingehender beleuchten.

Literaturverzeichnis

- Backhaus, Klaus; Erichson, Bernd; Plinke, Wulff; Weiber, Rolf: *Multivariate Analysemethoden*, 11. Aufl., Berlin, Heidelberg, New York 2006.
- Bijmolt, Tammo H. A.; Wedel, Michel: A Comparison of Multidimensional Scaling Methods for Perceptual Mapping, in: *Journal of Marketing Research*, 36/1999, S. 277-285.
- Borg, Ingwer; Groenen, Patrick J. K.: *Modern multidimensional scaling – Theory and Applications*, 2. Aufl., New York 2005.
- Borg, Ingwer; Staufenbiel, Thomas: *Theorien und Methoden der Skalierung*, 4. Aufl., Bern 2007.
- Brosius, Felix: *SPSS 16*, Heidelberg 2008.
- Bühl, Achim: *SPSS Version 16: Einführung in die moderne Datenanalyse*, 11. Aufl., München 2008.
- Carroll, J. Douglas; Green, Paul E.: Psychometric Methods in Marketing Research, Part II: Multidimensional Scaling, in: *Journal of Marketing Research*, 34/1997, S. 193-204.
- Green, Paul E.; Carmone, Frank, J.; Smith, Scott M.: *Multidimensional Scaling: Concepts and Applications*, Boston, London 1989.
- Hartung, Joachim; Elpelt, Bärbel: *Multivariate Statistik*, 7. Aufl., München, Wien 2007.
- Herrmann, Andreas; Homburg, Christian; Klarmann, Martin (Hrsg.): *Handbuch Marktforschung*, 3. Aufl., Wiesbaden 2008.
- Homburg, Christian; Pflesser, Christian; Klarmann, Martin: Strukturgleichungsmodelle mit latenten Variablen: Kausalanalyse, in: Herrmann et al. 2008, S. 547-577.
- Kappelhoff, Peter: *Multidimensionale Skalierung – Beispiele zur Datenanalyse*, Lehrstuhl für empirische Wirtschafts- und Sozialforschung, Wuppertal 2001.
- Koch, Jörg: *Marktforschung*, 4. Aufl., München, Wien 2004.
- Kroeber-Riel, Werner; Weinberg, Peter: *Konsumentenverhalten*, 8. Aufl., München 2003.
- Kruskal, Joseph B.; Wish, Myron: *Multidimensional Scaling*, 27. print, Newbury Park u.a. 2005.
- Litz, Hans Peter: *Multivariate Statistische Methoden*, München, Wien 2000.
- Mathar, Rudolf: *Multidimensionale Skalierung – mathematische Grundlagen und algorithmische Aspekte*, Stuttgart 1997.
- Meffert, Heribert; Burmann, Christoph; Kirchgeorg, Manfred: *Marketing*, 10. Aufl., Wiesbaden 2008.
- Nieschlag, Robert; Dichtl, Erwin; Hörschgen, Hans: *Marketing*, 19. Aufl., Berlin 2002.
- Quack, Helmut: *Die Einstellungsrelevanz von Produktmerkmalen – multidimensionale Messung und Bedeutung für die Wirkung von Werbebotschaften*, Frankfurt am Main 1980.
- SPSS Inc.: *SPSS Base 16.0 User's Guide Package*, Chicago 2007.
- Trommsdorff, Volker: *Konsumentenverhalten*, 6. Aufl., Stuttgart 2004.
- Trommsdorff, Volker: *Produktpositionierung*, in: Herrmann et al. 2008, S. 887-907.
- Wührer, Gerhard A.: *Mehrdimensionale Skalierung*, in: Herrmann et al. 2008, S. 305-333.

