

# Exploratorische Faktorenanalyse: Hauptachsenanalyse und Hauptkomponentenanalyse SPSS-Beispiel zu Kapitel 13<sup>1</sup>

Karin Schermelleh-Engel, Christina S. Werner & Helfried Moosbrugger

## Inhaltsverzeichnis

1	Vorbemerkungen.....	1
2	Empirischer Datensatz.....	3
3	Hauptachsenanalyse – Principal Axes Factor Analysis (PFA) .....	5
3.1	Hauptachsenanalyse mit drei Faktoren und obliquer Rotation .....	5
3.2	Hauptachsenanalyse mit zwei Faktoren und obliquer Rotation.....	12
4	Hauptkomponentenanalyse – Principal Component Analysis (PCA) .....	16
4.1	Hauptkomponentenanalyse mit zwei Faktoren und obliquer Rotation .....	17
4.2	Hauptkomponentenanalyse mit drei Faktoren und orthogonaler Rotation .....	21
5	Fazit.....	24
6	Literatur.....	24

## 1 Vorbemerkungen

Exploratorische Faktorenanalysen (EFA) werden in der Regel dann angewendet, wenn Zusammenhänge zwischen vielen beobachteten Variablen auf wenige hinter den Variablen vermutete Faktoren zurückgeführt werden sollen, der Untersucher aber keine konkreten Hypothesen hat über die Anzahl der einem Datensatz zugrunde liegenden Faktoren und über die Zuordnung der beobachteten Variablen zu den Faktoren. Tatsächlich bestehen - z. B. bei der Fragebogenentwicklung - oftmals sogar bereits Annahmen über die zu erwartende Anzahl an Faktoren und darüber, welche Items auf welchem Faktor laden sollten. Eine exakte statistische

---

<sup>1</sup> „IBM SPSS Statistics“ hieß früher „PASW Statistics“. - Alle Abbildungen in diesem Beitrag stammen aus dem Programm IBM SPSS Statistics, Release 18.0 2009. Chicago: SPSS, an IBM Company. Wir danken IBM für die freundliche Genehmigung zur Verwendung der Screenshots.

Prüfung dieser Hypothesen ist mit der EFA jedoch nicht möglich, sondern nur mit konfirmatorischen Faktorenanalysen (CFA), für die allerdings spezielle Programme für die Analyse von Strukturgleichungsmodellen benötigt werden (z.B. LISREL, Mplus, AMOS oder EQS, um nur einige zu nennen).

Da exploratorische Faktorenanalysen keine exakten Hypothesenprüfungen ermöglichen, erfordern die nachfolgend verwendeten Verfahren auch keine bestimmten Verteilungsannahmen. Sie basieren aber auf der Annahme linearer Zusammenhänge zwischen den beobachteten Variablen (z. B. Items) und den Faktoren, so dass die Ergebnisse nur dann sinnvoll interpretierbar sind, wenn die zu faktorisierenden Variablen (zumindest annähernd) als intervallskaliert betrachtet werden können. Auf Fragebogenitems (die hier faktorisiert werden sollen) trifft diese Annahme streng genommen zwar nicht unbedingt zu. In der Praxis werden Fragebogenitems aber in der Regel als annähernd intervallskaliert betrachtet, wenn die Antwortkategorien in etwa gleichabständig erscheinen (z.B. dann, wenn die End-Kategorien mit Worten bezeichnet sind und als Zwischenwerte gleichabständige Zahlen verwendet werden).

Leider werden exploratorische Faktorenanalysen oftmals unkritisch durchgeführt, ohne dass man sich der möglichen methodischen Probleme bewusst ist. Ein Problem exploratorischer Faktorenanalysen kann z. B. auch darin bestehen, dass außer substantiellen Faktoren zusätzlich auch Scheinfaktoren extrahiert werden, die daraus resultieren, dass Items mit ähnlichen Itemschwierigkeiten oder ähnlichen Symmetrieeigenschaften einen eigenen Faktor bilden können (vgl. Bernstein & Teng, 1989; Nunnally & Bernstein, 1994). Als Alternative zu den „klassischen“ Methoden bietet z.B. das Programm Mplus ein robustes Kleinstquadrat-schätzverfahren für ordinale Daten an (Muthén & Muthén, 2007).

Bei der exploratorischen Faktorenanalyse müssen verschiedene Entscheidungen getroffen werden, die Auswirkungen auf die Ergebnisse haben können:

1. Wahl der Extraktionsmethode, z.B. Hauptachsen- oder Hauptkomponentenanalyse;
2. Wahl der Anzahl der zu extrahierenden Faktoren, z.B. Vorgabe einer bestimmten Anzahl von Faktoren basierend auf theoretischen Überlegungen oder Verwendung von Abbruchkriterien, wie z.B. Kaiser-Kriterium oder Screeplot;
3. Wahl des Rotationsalgorithmus, z.B. schiefwinkliger (oblique) oder orthogonaler Rotation.

Zusätzlich zu den hier verwendeten Methoden gibt es noch weitere Extraktions- und Rotationsmethoden der exploratorischen Faktorenanalyse, die spezifische Vor- und Nachteile aufweisen (vgl. Costello et al., 2005; Fabrigar et al., 1999).

## 2 Empirischer Datensatz

Nachfolgend sollen die Konsequenzen dieser unterschiedlichen Entscheidungen am Beispiel eines empirischen Datensatzes aus der Schmerzforschung demonstriert werden. Der Beispieldatensatz „Schmerz.sav“ enthält jeweils sechs Items der Skalen „Schmerzintensität“ und „Depressivität“ des Fragebogens zur Schmerzregulation (FSR; Schermelleh-Engel, 1995), die auf ihre faktorielle Struktur hin überprüft werden sollen.

Die Skala „Schmerzintensität“ des FSR umfasst allgemeine Einschätzungen zur Stärke von Schmerzen und zu physiologischen Begleitsymptomen. Folgende sechs Items wurden ausgewählt:

Wenn ich Schmerzen habe ...

Item 1 (sch1): ...sind sie manchmal nicht mehr zum Aushalten

Item 2 (sch2): ...wird mir manchmal richtig übel davon

Item 3 (sch3): ...kann ich sie meist noch gut ertragen (-)

Item 4 (sch4): ...sind sie meist ziemlich stark

Item 5 (sch5): ...kann ich sie im allgemeinen gut aushalten (-)

Item 6 (sch6): ...sind sie häufig unerträglich

Die Skala „Depressivität“ des FSR umfasst Gefühle der Hilflosigkeit und Niedergeschlagenheit, die durch Schmerzen ausgelöst werden bzw. den Schmerz begleiten. Folgende sechs Items dieser Skala wurden ausgewählt:

Wenn ich Schmerzen habe ...

Item 1 (dep1): ...resigniere ich leicht

Item 2 (dep2): ...fühle ich mich ausgeliefert

Item 3 (dep3): ...fühle ich mich hilflos

Item 4 (dep4): ...fühle ich mich einsam

Item 5 (dep5): ...bin ich niedergeschlagen

Item 6 (dep6): ...kommt mir das Leben sinnlos vor

Die Antwortskala ist eine siebenstufige Likert-Skala mit den Endpunkten „1 = trifft gar nicht zu“ bis „7 = trifft vollkommen zu“. Die Daten entstammen einer Studie zum chronischen Schmerz (Schermelleh-Engel, Eifert, Moosbrugger & Frank, 1997), von der eine Teilstichprobe von  $N = 180$  Personen ausgewählt wurde. Die mit (-) markierten Items sind invers formuliert und wurden vor der Datenanalyse umkodiert.

	sch1	sch2	sch3	sch4	sch5	sch6	dep1	dep2	dep3	dep4	dep5	dep6
1	5	7	6	6	3	5	6	5	5	5	4	3
2	6	7	2	5	3	3	2	2	2	1	2	1
3	7	7	5	7	5	6	3	2	3	2	6	2
4	3	2	4	5	4	3	4	2	2	4	3	1
5	4	4	3	2	5	3	4	5	5	5	5	2
6	5	1	5	5	4	2	4	4	2	1	5	1
7	3	2	3	3	4	3	2	5	3	2	3	1
8	3	3	2	4	1	2	1	1	1	1	3	1
9	7	2	6	7	2	7	7	6	5	6	6	7
10	6	1	4	6	5	6	5	7	7	5	5	2
11	6	2	2	2	1	3	4	1	1	1	5	1
12	6	6	7	7	6	7	2	6	7	6	6	1
13	5	1	4	4	4	4	1	5	4	3	5	2
14	1	1	1	2	1	1	4	1	5	1	5	1
15	6	7	7	7	7	6	4	5	4	1	5	1
16	6	7	2	6	3	6	3	2	2	3	5	1
17	6	2	4	6	3	3	3	4	3	6	4	3
18	5	1	3	5	2	4	1	2	1	5	1	1
19	4	1	1	4	1	1	2	7	7	1	1	1
20	2	5	4	7	2	2	1	4	2	3	3	1
21	5	6	4	6	5	4	3	3	4	2	5	1
22	7	5	4	6	6	7	5	7	6	6	6	7
23	6	6	6	6	6	6	1	7	5	6	1	4
24	5	7	4	5	4	4	5	7	5	4	6	5
25	6	6	5	6	4	5	5	5	5	1	2	1
26	5	2	3	6	5	5	4	4	4	2	5	1

Abbildung 1. Daten-Editor mit den Rohdaten der Datendatei „Schmerz.sav“.

Nach dem Starten des Programms SPSS wird die Datei „Schmerz.sav“ geladen. Der Daten-Editor (s. Abbildung 1) zeigt die Rohwerte der 180 Personen an, die in 180 Zeilen (für die Personen) und 12 Spalten (für die Items) angeordnet sind. Die ersten sechs Spalten beinhalten die Antworten auf die sechs Items der Skala „Schmerzintensität“, jeweils mit „sch“ bezeichnet, die weiteren sechs Spalten die Antworten auf die sechs Items der Skala „Depressivität“, jeweils mit „dep“ bezeichnet.

Zunächst wird entschieden, welche Extraktionsmethode und welche Rotationsmethode verwendet werden sollen. Wenn man das Ziel hat, die Faktoren als latente Variablen interpretieren zu können, welche die Korrelationen zwischen den Items erklären, sollte man die *Hauptachsenanalyse* (engl. principal axes factor analysis, PFA) wählen. Möchte man dagegen einfach nur eine Datenreduktion vornehmen, so würde man die *Hauptkomponentenanalyse* (engl. principal component analysis, PCA) als Extraktionsmethode anwenden. Bei den vorliegenden Fragebogenitems ist davon auszugehen, dass die Antworten auf die Items Messfehler enthalten, und dass es sich bei den mit den Items erfassten Konstrukten "Schmerzintensität" und "Depressivität" um latente Variablen handeln könnte. Daher sollte man sich für die Hauptachsenanalyse entscheiden. Da von den Inhalten der Items erwartet werden könnte, dass potentiell dahinter

stehende latente Variablen wie "Schmerzintensität" und "Depressivität" miteinander korrelieren, würde man hier zur Rotation vorzugsweise eine oblique (schiefwinklige) und keine orthogonale Rotationsmethode wählen.

Zu Demonstrationszwecken soll nachfolgend gezeigt werden, wie die Hauptachsenanalyse (PFA) und die Hauptkomponentenanalyse (PCA) als Methoden der exploratorischen Faktorenanalyse (EFA) mit SPSS durchgeführt werden können. Zum Vergleich werden neben der hier empfehlenswerten obliquen Rotation auch Ergebnisse einer orthogonalen (Varimax-) Rotation gezeigt.

### 3 Hauptachsenanalyse – Principal Axes Factor Analysis (PFA)

#### 3.1 Hauptachsenanalyse mit drei Faktoren und obliquen Rotation

Bei der Hauptachsenanalyse (PFA) wird davon ausgegangen, dass die einzelnen beobachteten Variablen nicht nur wahre Varianz, sondern auch Messfehlervarianz aufweisen. Ziel der PFA ist es, latente Konstrukte bzw. Faktoren zu identifizieren, auf die die Zusammenhänge der Variablen zurückgeführt werden können. Dabei soll nicht die gesamte Varianz der Variablen durch Faktoren erklärt werden, sondern lediglich die wahre Varianz.

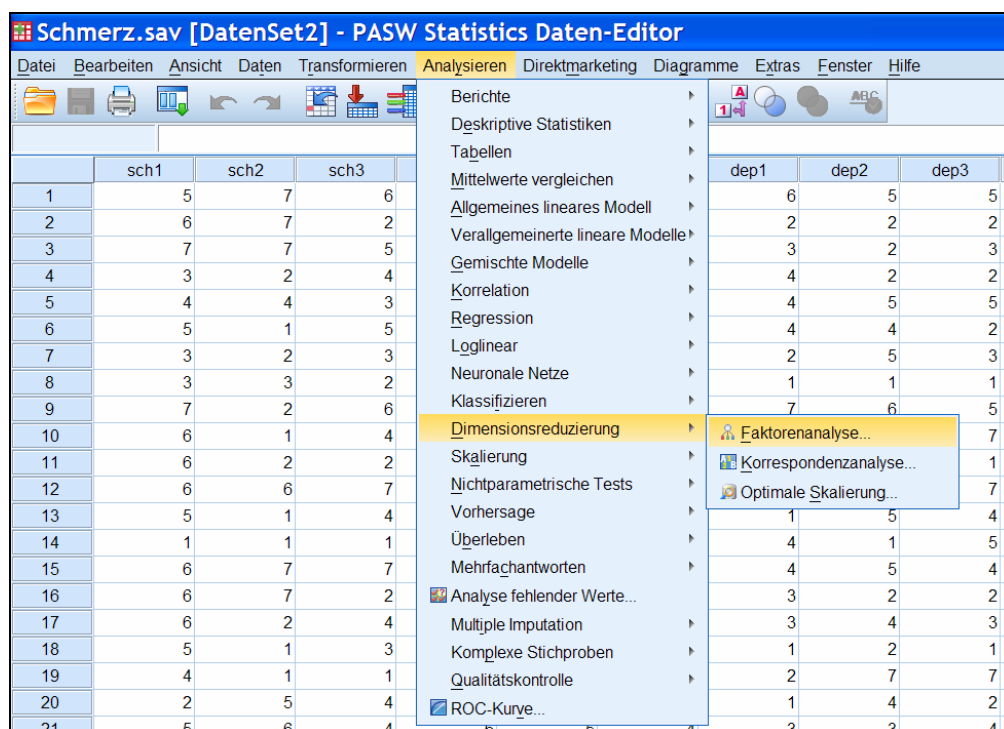


Abbildung 2. Auswahl des Menüs *Faktorenanalyse*.

Zur Auswahl der Hauptachsenanalyse muss zunächst im Daten-Editor das Menü *Analysieren* → *Dimensionsreduzierung* → *Faktorenanalyse* aufgerufen werden (s. Abbildung 2).

Im Menüfenster (s. Abbildung 3) sind nun links die Variablen (Items) untereinander in einem Feld angeordnet. Da in die Faktorenanalyse alle Variablen eingehen sollen, werden alle 12 Items markiert und durch das Anklicken des Pfeils in der Mitte in das rechte Feld mit der Bezeichnung „Variablen“ übertragen.

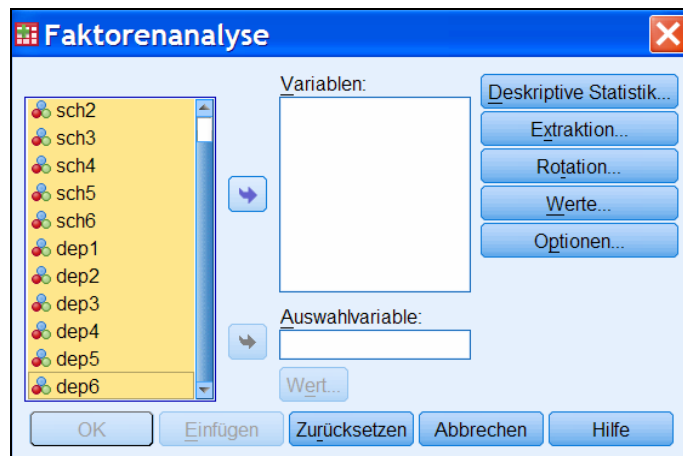


Abbildung 3. Auswahl der Items für die Analyse im Menü *Faktorenanalyse*.

Im Fenster *Faktorenanalyse* (s. Abbildung 4) wird zunächst das Untermenü „Extraktionsmethode“ aufgerufen und unter „Methode“ die Extraktionsmethode ausgewählt. Voreingestellt ist die Hauptkomponentenanalyse, die hier aber nicht verwendet werden soll.

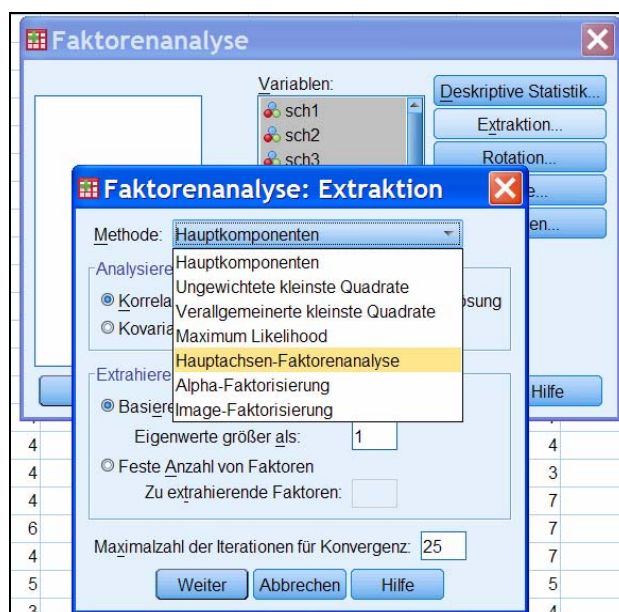


Abbildung 4. Auswahl der Hauptachsenanalyse („Hauptachsen-Faktorenanalyse“) als „Methode“ im Untermenü „Extraktion“.

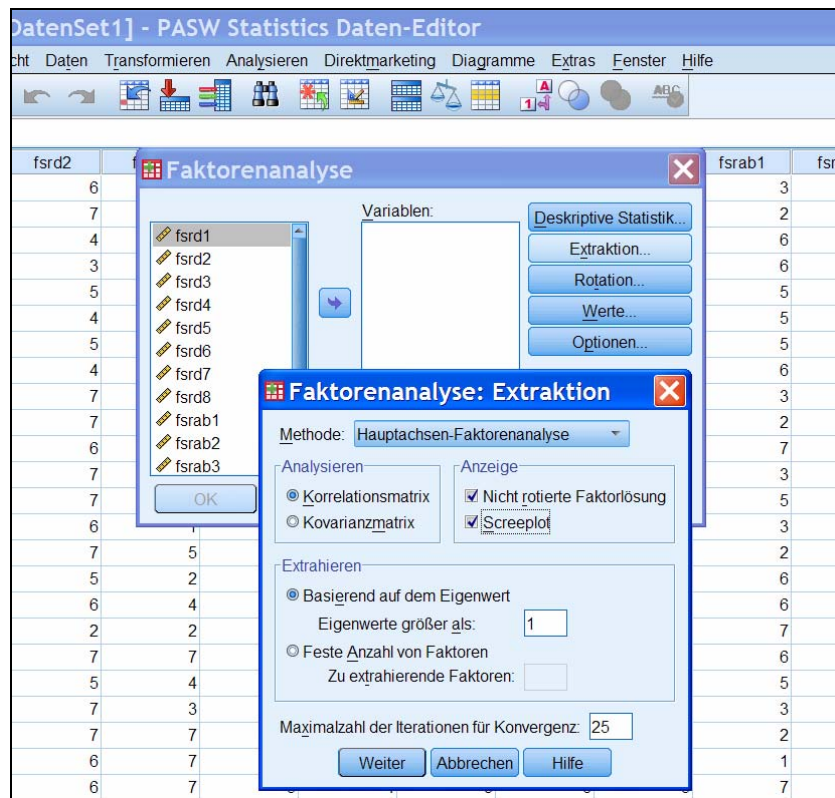


Abbildung 5. Vorgabe der Anzahl zu extrahierender Faktoren auf der Basis der Eigenwerte im Untermenü „Extraktion“.

Aus den verschiedenen Extraktionsmethoden (s. Abbildung 5) wird die Hauptachsenmethode ausgewählt, die in SPSS mit „Hauptachsen-Faktorenanalyse“ bezeichnet wird. Die meisten Voreinstellungen dieses Untermenüs werden üblicherweise übernommen: Es soll die Korrelationsmatrix analysiert (Voreinstellung unter „Analysieren“) und die nicht rotierte Faktorlösung (Voreinstellung unter „Anzeige“) ausgegeben werden. Unter „Extrahieren“ wird die Option „Basierend auf dem Eigenwert - Eigenwerte größer als 1“ (Kaiser-Kriterium) und unter „Anzeige“ die Option „Screeplof“ markiert, womit eine graphische Darstellung des Eigenwertverlaufs angefordert wird. Anhand des Screeplots soll überprüft werden, ob möglicherweise mehr oder weniger Faktoren angemessen sein könnten, als nach dem Kriterium "Eigenwerte größer 1" extrahiert würden.

Als nächstes wird die Rotationsmethode ausgewählt. Hierzu wird im Menü *Faktorenanalyse* das Untermenü „Rotation“ ausgewählt (s. Abbildung 6). Unter „Methode“ ist als Voreinstellung „keine“ markiert. Um eine schiefwinkliger Rotation zu erhalten, wird „Oblimin, direkt“ angeklickt. Unter „Anzeige“ ist „Rotierte Lösung“ bereits per Voreinstellung markiert, so dass die Faktorladungen der rotierten Lösung ausgegeben werden. Gelegentlich (bei Daten mit weniger klarer faktorieller Struktur) genügt evtl. die Voreinstellung von 25 Iterationen noch

nicht, um zu einer Lösung zu kommen. In solchen Fällen könnten hier dann auch höhere Werte für die Maximalzahl Iterationen vorgegeben werden.

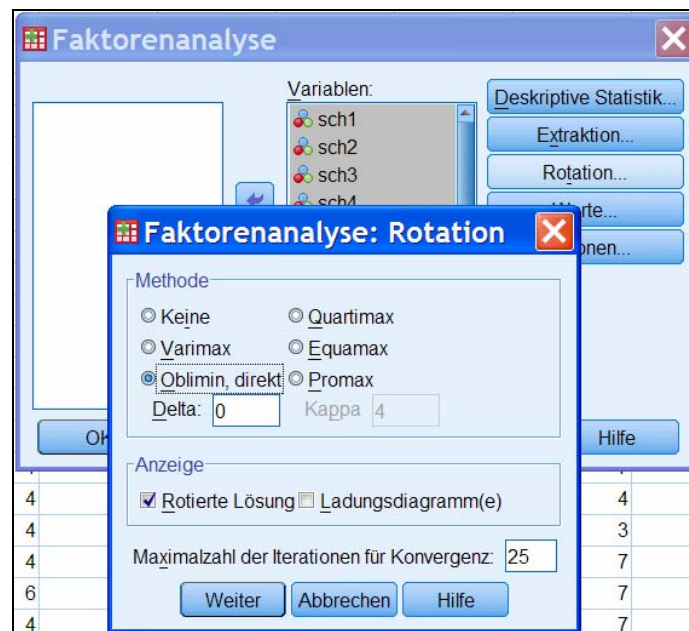


Abbildung 6. Auswahl der Rotationsmethode: Als schiefwinklige Rotationsmethode wird „Oblimin, direkt“ durch Anklicken ausgewählt.

Durch „Weiter“ wird das Fenster geschlossen und das Fenster *Faktorenanalyse* wieder angezeigt. Anklicken von „OK“ führt zur Durchführung der Hauptachsenanalyse. Die Ergebnisse der Analyse sind im Statistics Viewer in der Datei „Ausgabe1.spv“ tabellarisch aufgeführt und werden automatisch angezeigt.

Als Ergebnisse der Hauptachsenanalyse (Tabelle 1) werden zunächst die Kommunalitäten ausgegeben. In der Spalte „Anfänglich“ sind die Ausgangsschätzungen der Kommunalitäten vor der Extraktion angegeben, die auf den quadrierten multiplen Korrelationen jedes Items mit allen übrigen Items basieren. Mit der quadrierten multiplen Korrelation wird das Ausmaß der wahren Varianz der beteiligten Variablen abgeschätzt, da es sich bei gemeinsamer Varianz ja nicht um zufällige Messfehleranteile handeln kann, und von der in den Items enthaltenen Fehlervarianz vor der Faktorisierung getrennt (vgl. den Unterschied zur Hauptkomponentenanalyse, s.u.). Die Spalte „Extraktion“ gibt die tatsächlichen Kommunalitäten nach erfolgter Extraktion wieder, nämlich die Summe der quadrierten Faktorladungen über alle extrahierten Faktoren in der "Faktormatrix" (s.u., Tabelle 2). Nach dem Kaiser-Kriterium wurden hier drei Faktoren mit Eigenwerten größer als eins berücksichtigt.



Tabelle 1. SPSS-Ausgabe: Kommunalitäten und erklärte Gesamtvarianz der Hauptachsenanalyse mit obliquen Rotation von drei Faktoren.

Kommunalitäten		
	Anfänglich	Extraktion
sch1	.516	.561
sch2	.312	.329
sch3	.462	.533
sch4	.543	.622
sch5	.488	.751
sch6	.695	.760
dep1	.389	.388
dep2	.690	.668
dep3	.684	.672
dep4	.359	.376
dep5	.515	.543
dep6	.463	.501

Faktor	Erklärte Gesamtvarianz						Rotierte Summe der quadrierten Ladungen
	Anfängliche Eigenwerte			Summen von quadrierten Faktorladungen für Extraktion			
	Gesamt	% der Varianz	Kumulierte %	Gesamt	% der Varianz	Kumulierte %	Gesamt
1	5.520	45.998	45.998	5.102	42.520	42.520	4.363
2	1.371	11.429	57.427	.951	7.928	50.447	3.743
3	1.047	8.721	66.148	.650	5.418	55.865	2.526
4	.699	5.827	71.975				
5	.670	5.584	77.559				
6	.598	4.982	82.541				
7	.520	4.336	86.877				
8	.426	3.550	90.427				
9	.392	3.265	93.693				
10	.338	2.818	96.511				
11	.256	2.136	98.647				
12	.162	1.353	100.000				

In der Tabelle „Erklärte Gesamtvarianz“ sind unter „anfängliche Eigenwerte - Gesamt“ die maximal erzielbaren Eigenwerte aufgeführt, die man bei Extraktion aller 12 möglichen Faktoren (so viele, wie Variablen in die Analyse eingehen) und ohne Unterscheidung zwischen wahrer

und Fehlervarianz erhalten könnte (d.h. im Sinne einer Hauptkomponentenanalyse, s.u.). Die 12 Eigenwerte ergeben aufsummiert den Wert 12, da die Summe der Varianzen der standardisierten Variablen 12 ist. In den Spalten daneben stehen die Prozentanteile an der Gesamtvarianz der 12 Items, die mit dem jeweiligen Faktor erklärt werden.

Nach dem Kaiser-Kriterium, das von SPSS als Voreinstellung zur Bestimmung der Anzahl der zu extrahierenden Faktoren verwendet wird, wurden alle Faktoren mit Eigenwerten größer als eins als bedeutsam erachtet; dies sind im vorliegenden Fall drei Faktoren (mit den Eigenwerten 5.520, 1.371 und 1.047, s. Tabelle 1).

Es soll aber noch überprüft werden, ob die Anzahl von drei zu extrahierenden Faktoren (nach dem Kaiser-Kriterium) auch durch den Screeplot (Abbildung 7) bestätigt werden kann.




Abbildung 7. Screeplot mit einem „Knick“ im Eigenwerteverlauf beim vierten Faktor.

Nach dem Screeplot werden alle Faktoren als bedeutsam angesehen, die vor dem „Knick“ im Eigenwerteverlauf liegen. Ein „Knick“ ist hier beim vierten Faktor zu erkennen, so dass die Anzahl von drei Faktoren auch mit dem Screeplot bestätigt würde. (Die Interpretation des Screeplots bei Hauptachsenanalysen ist allerdings etwas problematisch, da SPSS hier grundsätzlich den Eigenwerteverlauf darstellt, den man ohne Unterscheidung zwischen wahrer und Fehlervarianz erhalten würde (d.h. im Sinne einer Hauptkomponenten- und nicht einer Hauptachsenanalyse, s.u.), so dass die Ergebnisse mit Vorsicht interpretiert werden sollten.)

Es wurden nun mit der Hauptachsenanalyse entsprechend dem Kaiser-Kriterium drei Faktoren extrahiert (s. Tabelle 1, „Erklärte Gesamtvarianz“). Da im Rahmen der Hauptachsenanalyse aber nur wahre Varianz der Items erklärt werden soll, sind die Eigenwerte dieser Faktoren (Spalte „Summen von quadrierten Faktorladungen - Gesamt“), also die von den jeweiligen Faktoren über alle Items zusammen erklärten Varianzen nach der Extraktion etwas geringer (hier: 5.102, .951, .650) als die „anfänglichen“ Eigenwerte (5.520, 1.371, 1.047). Die Summe dieser Eigenwerte kann - für standardisierte Variablen - maximal so groß werden wie die Anzahl der Items (hier: 12) und entspricht der Summe der tatsächlichen Kommunalitäten in der oberen Tabelle (Spalte „Extraktion“). Bezogen auf die maximal erklärbare Gesamtvarianz der Items (hier: 12) erklären die drei Faktoren zusammen also 55.9%:  $(5.102 + .951 + .650) / 12 = .559$ .

In der SPSS-Ausgabe sind danach vier Matrizen aufgeführt (Tabelle 2), die Faktorenmatrix mit den Ladungen auf den unrotierten Faktoren, die Mustermatrix mit den Ladungen auf den rotierten Faktoren, die Strukturmatrix mit den Korrelationen zwischen den Items und den Faktoren und schließlich die Korrelationsmatrix der Faktoren untereinander.

Tabelle 2. SPSS-Ausgabe: Faktorenmatrix, Mustermatrix, Strukturmatrix und Faktor-Korrelationsmatrix der dreifaktoriellen Hauptachsenanalyse mit obliquen Rotation.

Faktorenmatrix				Mustermatrix				Strukturmatrix			
	Faktor				Faktor				Faktor		
	1	2	3		1	2	3		1	2	3
sch1	.669	.287	.177	sch1	.065	.659	-.102	sch1	.491	.740	-.409
sch2	.516	.168	.186	sch2	.109	.501	-.005	sch2	.403	.566	-.263
sch3	.583	.302	-.312	sch3	.009	.239	-.588	sch3	.392	.494	-.693
sch4	.603	.393	.323	sch4	-.095	.847	.017	sch4	.392	.785	-.303
sch5	.623	.251	-.555	sch5	.095	.010	-.823	sch5	.443	.415	-.866
sch6	.819	.270	.132	sch6	.173	.664	-.176	sch6	.633	.839	-.530
dep1	.591	-.188	-.057	dep1	.557	.014	-.116	dep1	.613	.388	-.353
dep2	.741	-.336	-.079	dep2	.811	-.078	-.109	dep2	.811	.441	-.412
dep3	.722	-.384	-.051	dep3	.853	-.104	-.055	dep3	.815	.416	-.365
dep4	.526	-.256	.184	dep4	.590	.125	.175	dep4	.590	.394	-.123
dep5	.712	-.185	-.043	dep5	.624	.074	-.132	dep5	.722	.494	-.422
dep6	.651	-.254	.113	dep6	.662	.117	.072	dep6	.701	.472	-.253

Korrelationsmatrix für Faktor			
Faktor	1	2	3
1	1.000	.583	-.415
2	.583	1.000	-.424
3	-.415	-.424	1.000

Die Ladungen auf den unrotierten Faktoren in der *Faktorenmatrix* können in der Regel nicht interpretiert werden, weil typischerweise alle Items auf dem ersten Faktor relativ hoch laden. Für jedes Item ergibt die Summe der quadrierten Ladungen in dieser Faktorenmatrix die Kommunalität nach der Extraktion, also z.B. für Item „sch1“:  $.669^2 + .287^2 + .177^2 = .561$ .

Erst durch die Rotation resultiert aber ein interpretierbares Muster an Faktorladungen, das in der *Mustermatrix* enthalten ist. Wie Tabelle 2 zeigt, bewirkt die schiefwinklige Rotation eine Einfachstruktur in dem Sinne, dass die Items nur noch auf jeweils einem Faktor hoch laden (Mustermatrix): Auf dem ersten Faktor laden alle Depressivitätsitems, auf dem zweiten Faktor alle Schmerzintensitätsitems mit Ausnahme der Items „sch3“ und „sch5“, die wiederum hoch auf dem dritten Faktor laden. Eine Inspektion dieser beiden Items ergibt, dass es sich hierbei um die beiden invertierten Items handelt, die hier einen eigenen Faktor bilden. Es handelt sich bei dem dritten extrahierten Faktor somit offenbar um einen Methodenfaktor, der inhaltlich dann nicht bedeutsam wäre.

Da aufgrund der Skalenkonstruktion erwartet werden konnte, dass die Items nur auf zwei und nicht auf drei Faktoren laden, und es sich beim dritten Faktor offenbar um einen Methodenfaktor handelt, der inhaltlich nicht bedeutsam wäre, soll nachfolgend überprüft werden, ob auch schon zwei Faktoren das Beziehungsmuster zwischen den Items hinreichend erklären könnten.

### **3.2 Hauptachsenanalyse mit zwei Faktoren und obliquen Rotation**

Nachfolgend soll die Hauptachsenanalyse noch einmal durchgeführt werden, dieses Mal aber mit der Vorgabe, dass zwei Faktoren extrahiert werden sollen (s. Abbildung 8), um zu sehen, ob die bei der Testkonstruktion intendierten zwei Skalen eine faktorenanalytische Unterstützung finden. Dazu wird im Fenster *Faktorenanalyse* das Untermenü „Extraktion“ aufgerufen und unter „Extrahieren“ die Option „Feste Anzahl von Faktoren“ markiert und als Zahl die „2“ eingegeben. Mit „Weiter“ wird das Fenster geschlossen.

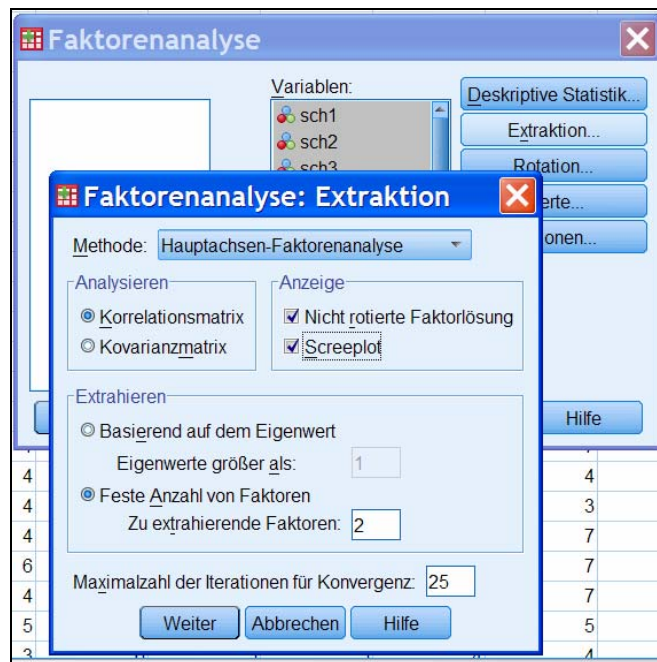


Abbildung 8. Vorgabe von zwei zu extrahierenden Faktoren im Untermenü „Extraktion“.

Die übrigen Einstellungen in den Menüs „Extraktion“ und „Rotation“ werden gegenüber der vorigen Analyse nicht verändert (wobei der Screeplot dieses Mal nicht unbedingt angefordert werden müsste, weil dieser ja bereits vorliegt). Auch in dieser Analyse wird wieder eine oblique Rotation der Faktoren vorgenommen. Die Ergebnisse der Analyse sind wiederum im Statistics Viewer in der Datei „Ausgabe1.spv“ unterhalb der Ergebnisse der ersten Analyse tabellarisch dargestellt und werden automatisch angezeigt (s. Tabelle 3).

Als Ergebnisse der Hauptachsenanalyse mit der Vorgabe von zwei zu extrahierenden Faktoren (Tabelle 3) werden zunächst wiederum die Kommunalitäten ausgegeben, die nun überwiegend etwas geringer sind als bei der dreifaktoriellen Lösung, was sich dadurch erklären lässt, dass nun ja nur zwei Faktoren die Varianzen der Items erklären.

Tabelle 3. SPSS-Ausgabe: Kommunalitäten und erklärte Gesamtvarianz der Hauptachsenanalyse mit obliquen Rotation von zwei Faktoren.

Kommunalitäten		
	Anfänglich	Extraktion
sch1	.516	.559
sch2	.312	.304
sch3	.462	.374
sch4	.543	.514
sch5	.488	.348
sch6	.695	.778
dep1	.389	.387
dep2	.690	.671
dep3	.684	.685
dep4	.359	.319
dep5	.515	.545
dep6	.463	.473

Faktor	Erklärte Gesamtvarianz						
	Anfängliche Eigenwerte			Summen von quadrierten Faktorladungen für Extraktion			Rotierte Summe der quadrierten Ladungen
	Gesamt	% der Varianz	Kumulierte %	Gesamt	% der Varianz	Kumulierte %	Gesamt
1	5.520	45.998	45.998	5.053	42.110	42.110	4.436
2	1.371	11.429	57.427	.904	7.531	49.641	4.258
3	1.047	8.721	66.148				
4	.699	5.827	71.975				
5	.670	5.584	77.559				
6	.598	4.982	82.541				
7	.520	4.336	86.877				
8	.426	3.550	90.427				
9	.392	3.265	93.693				
10	.338	2.818	96.511				
11	.256	2.136	98.647				
12	.162	1.353	100.000				

In der Tabelle „Erklärte Gesamtvarianz“ sind unter „anfängliche Eigenwerte - Gesamt“ wiederum die maximal erzielbaren Eigenwerte aufgeführt, die man bei Extraktion aller 12 möglichen Faktoren (soviele, wie Variablen in die Analyse eingehen) und ohne Unterscheidung

zwischen wahrer und Fehlervarianz erhalten könnte (d.h. im Sinne einer Hauptkomponentenanalyse, s.u.). Die 12 Eigenwerte ergeben aufsummiert den Wert 12, da die Summe der Varianzen der standardisierten Variablen 12 ist. In den Spalten daneben stehen die Prozentanteile an der Gesamtvarianz der 12 Items, die in diesem Fall dann erklärt würden. Tatsächlich wurden nun mit der Hauptachsenanalyse nur zwei Faktoren mit Eigenwerten größer als eins extrahiert; sie erklären zusammen jetzt nur noch ca. 50% der Varianz der Items.

Tabelle 4. SPSS-Ausgabe: Faktorenmatrix, Mustermatrix, Strukturmatrix und Korrelationsmatrix der Faktoren der zweifaktoriellen Hauptachsenanalyse mit obliquen Rotation.

Faktorenmatrix			Mustermatrix			Strukturmatrix		
	Faktor			Faktor			Faktor	
	1	2		1	2		1	2
sch1	.671	.329	sch1	-.003	.749	sch1	.493	.748
sch2	.515	.197	sch2	.064	.507	sch2	.399	.549
sch3	.565	.234	sch3	.049	.578	sch3	.431	.611
sch4	.593	.402	sch4	-.136	.799	sch4	.392	.709
sch5	.575	.132	sch5	.177	.458	sch5	.479	.575
sch6	.824	.313	sch6	.106	.808	sch6	.640	.878
dep1	.595	-.184	dep1	.568	.079	dep1	.620	.454
dep2	.746	-.338	dep2	.840	-.032	dep2	.819	.523
dep3	.729	-.391	dep3	.893	-.106	dep3	.824	.485
dep4	.524	-.211	dep4	.558	.010	dep4	.565	.379
dep5	.716	-.177	dep5	.630	.150	dep5	.729	.567
dep6	.652	-.219	dep6	.643	.066	dep6	.686	.490

Korrelationsmatrix für Faktor		
Faktor	1	2
1	1.000	.661
2	.661	1.000

Wie Tabelle 4 zu entnehmen ist, laden vor der Rotation ebenso wie schon bei der dreifaktoriellen Lösung alle Items hoch auf dem ersten Faktor (Faktorenmatrix). Die schiefwinklige Rotation bewirkt wiederum eine Einfachstruktur in dem Sinne, dass die Items nur noch auf jeweils einem Faktor hoch laden (Mustermatrix). Es ergibt sich hier aber nun ein etwas anderes Muster als bei der dreifaktoriellen Lösung: Auf dem ersten Faktor laden nun alle Schmerzintensitätsitems, auch die invertierten Items, auf dem zweiten Faktor alle Depressivitätsitems. Somit scheint es sich bei dem vorher extrahierten dritten Faktor tatsächlich um einen nicht bedeutsamen Methodenfaktor gehandelt zu haben. Solche Methodenfaktoren können zusätzlich zu inhaltlichen Faktoren

insbesondere dann resultieren, wenn einige Items negativ gepolt, alle anderen aber positiv gepolt sind (vgl. Bernstein & Teng, 1989; Nunnally & Bernstein, 1994; Podsakoff, MacKenzie, Lee & Podsakoff, 2003; s. auch Jonkisz & Moosbrugger, 2007). Die zweifaktorielle Lösung erscheint somit plausibler und sie entspricht auch den Annahmen, die aus den Iteminhalten abgeleitet werden können. Deshalb sollten zwei Faktoren interpretiert werden.

#### **4 Hauptkomponentenanalyse – Principal Component Analysis (PCA)**

Oftmals wird angenommen, dass die Hauptkomponentenanalyse (PCA) vergleichbar mit der Hauptachsenanalyse (PFA) sei, obwohl sich die beiden Verfahren grundsätzlich voneinander unterscheiden (vgl. Fabrigar, Wegener, MacCallum & Strahan, 1999; Moosbrugger & Schermelleh-Engel, 2007). Bei der PCA handelt es sich um ein Datenreduktionsverfahren, bei dem die „Faktoren“ (Hauptkomponenten) als Linearkombinationen aus den Items gebildet werden. Fehleranteile der Items werden nicht herausgerechnet (die implizit getroffene, aber meist nicht zutreffende Annahme ist, dass alle Items messfehlerfrei seien), so dass in den Hauptkomponenten tatsächlich Messfehleranteile enthalten sein können.

Als Konsequenz kann erwartet werden, dass die Faktorladungen bei einer Hauptkomponentenanalyse höher ausfallen als bei einer Hauptachsenanalyse, da mit den Hauptkomponenten über die wahren Varianzanteile hinaus nun potentiell auch Messfehleranteile "erklärt" werden können, die in den Variablen enthalten sind, so dass künstlich höhere Zusammenhänge zwischen Hauptkomponenten und Variablen resultieren. Des weiteren kann erwartet werden, dass Korrelationen zwischen oblique rotierten Hauptkomponenten geringer sein werden als zwischen entsprechenden Faktoren in der Hauptachsenanalyse, da in den rotierten Hauptkomponenten Messfehleranteile von unterschiedlichen Items enthalten sind, wodurch sich die Korrelationen verringern.

Dessen ungeachtet wird die PCA häufiger als alle anderen Methoden der exploratorischen Faktorenanalyse eingesetzt. Costello und Osborne (2005) untersuchten 1700 in PsycINFO erfasste Studien über einen Zeitraum von zwei Jahren, in denen die exploratorische Faktorenanalyse angewandt worden war. In mehr als der Hälfte dieser Studien wurde eine PCA mit Varimax-Rotation durchgeführt, und am häufigsten wurde das Kaiser-Kriterium für die Bestimmung der Anzahl der Faktoren verwendet (und dies vermutlich nicht zuletzt deshalb, weil es die Standardeinstellungen in SPSS sind).



Da dieses Verfahren so häufig angewendet wird, soll es nachfolgend ebenfalls auf die Schmerzdaten angewandt werden, um deutlich zu machen, dass es potentiell auch zu anderen Ergebnissen als eine Hauptachsenanalyse führen kann. Zunächst soll die PCA vergleichbar zur letzten PFA durchgeführt werden, d.h. mit zwei extrahierten Faktoren und obliquen Rotation, um einen direkten Vergleich zu dieser Analyse zu ermöglichen. Danach soll noch eine PCA mit drei extrahierten Faktoren (nach dem Kaiser-Kriterium) und orthogonaler Rotation (Varimax-Rotation) durchgeführt werden, eine Vorgehensweise, die offensichtlich von sehr vielen Forschern verwendet wird, weil es sich um die Standardeinstellungen handelt.

#### 4.1 Hauptkomponentenanalyse mit zwei Faktoren und obliquen Rotation

Zur Durchführung der PCA wird im Fenster *Faktorenanalyse* unter der Option „Extraktion“ die Methode „Hauptkomponentenanalyse“ ausgewählt, die bei Aufruf des Programms voreingestellt ist (Abbildung 9). Auch hier soll die Korrelationsmatrix analysiert werden (Voreinstellung unter „Analysieren“) und - wie im letzten PFA-Beispiel - eine feste Anzahl von Faktoren vorgegeben werden, indem unter „Extrahieren“ die Option „Feste Anzahl von Faktoren“ angeklickt und als Zahl die „2“ eingegeben wird. Ein Screeplot wird nicht noch einmal benötigt, weil dieser im Programm SPSS immer den Eigenwerteverlauf darstellt, den man ohne Unterscheidung zwischen wahrer und Fehlervarianz erhalten würde (d.h. im Sinne einer Hauptkomponentenanalyse) und der somit dem gleichen würde, der bereits bei der Hauptachsenanalyse ausgegeben wurde. Mit „Weiter“ wird das Fenster geschlossen.

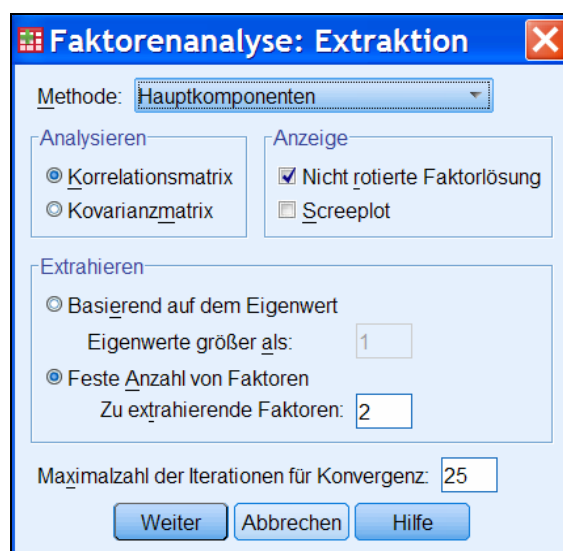


Abbildung 9. Auswahl der Hauptkomponentenanalyse und Vorgabe von zwei zu extrahierenden Faktoren.

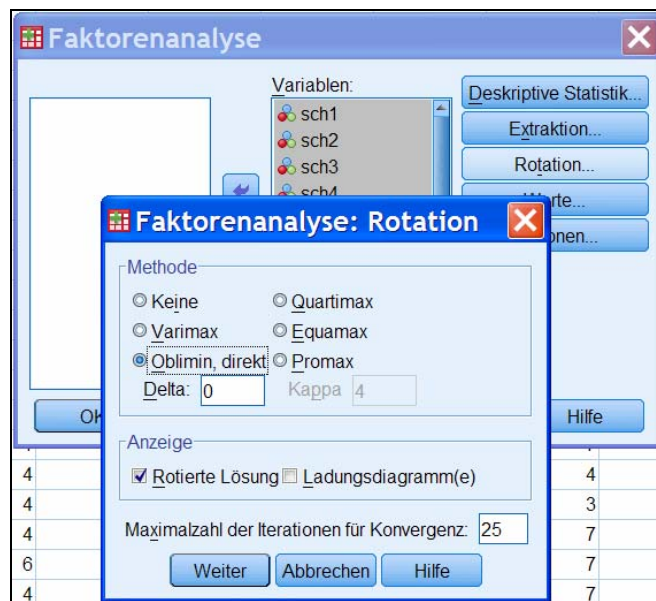


Abbildung 10. Auswahl der Rotationsmethode: Als schiefwinklige Rotationsmethode wird „Oblimin, direkt“ durch Anklicken ausgewählt.

Als nächstes wird die Rotationsmethode analog zur PFA ausgewählt (s. Abbildung 10). Hierzu wird im Fenster *Faktorenanalyse* das Untermenü „Rotation“ und unter „Methode“ „Oblimin, direkt“ angeklickt. Durch „Weiter“ wird das Fenster geschlossen und das Fenster *Faktorenanalyse* wieder angezeigt. Anklicken von „OK“ führt zur Durchführung der Hauptkomponentenanalyse. Die Ergebnisse der aktuellen Analyse sind im Statistics Viewer in der Datei „Ausgabe1.spv“ unterhalb der bisherigen Analyseergebnissen aufgeführt und werden automatisch angezeigt.

Wie Tabelle 5 (s.u.) zu entnehmen ist, sind in der PCA die anfänglichen Kommunalitäten unter „Kommunalitäten“ auf eins gesetzt (Annahme von messfehlerfreien Items), während die Kommunalitäten nach Extraktion von zwei Faktoren deutlich geringer als eins sind. Die Werte sind - wie erwartet - fast durchweg deutlich höher als diejenigen der PFA in Tabelle 3. Das Item „sch3“ weist z.B. eine Kommunalität von .519 (PCA) im Vergleich zu .374 (PFA) auf. Unter „Erklärte Gesamtvarianz“ in Tabelle 5 zeigen sich entsprechend auch höhere kumulierte Varianzanteile: Es werden nun ca. 57% der Gesamtvarianz durch die zwei Faktoren erklärt gegenüber ca. 50% in der PFA.

Tabelle 5. SPSS-Ausgabe: Kommunalitäten und erklärte Gesamtvarianz der Hauptkomponentenanalyse mit obliquen Rotation von zwei Faktoren.

	Anfänglich	Extraktion
sch1	1.000	.621
sch2	1.000	.397
sch3	1.000	.519
sch4	1.000	.609
sch5	1.000	.456
sch6	1.000	.755
dep1	1.000	.480
dep2	1.000	.692
dep3	1.000	.701
dep4	1.000	.469
dep5	1.000	.608
dep6	1.000	.584

Komponente	Anfängliche Eigenwerte			Summen von quadrierten Faktorladungen für Extraktion			Rotierte Summe der quadrierten Ladungen
	Gesamt	% der Varianz	Kumulierte %	Gesamt	% der Varianz	Kumulierte %	Gesamt
1	5.520	45.998	45.998	5.520	45.998	45.998	4.679
2	1.371	11.429	57.427	1.371	11.429	57.427	4.517
3	1.047	8.721	66.148				
4	.699	5.827	71.975				
5	.670	5.584	77.559				
6	.598	4.982	82.541				
7	.520	4.336	86.877				
8	.426	3.550	90.427				
9	.392	3.265	93.693				
10	.338	2.818	96.511				
11	.256	2.136	98.647				
12	.162	1.353	100.000				

Die PCA-Ergebnisse in Tabelle 6 (s.u.) weisen zu den PFA-Ergebnissen in Tabelle 4 vergleichbare Ladungsmuster auf, jedoch sind die Faktorladungen der PCA in den meisten Fällen höher. Dies zeigt sich z.B. in der Mustermatrix, in der die Ladungen auf der jeweiligen

Primärkomponente in der Regel höher, auf der jeweiligen Sekundärkomponente dagegen niedriger sind als auf den entsprechenden Faktoren in der PFA. Das Item „sch5“ lädt z.B. bei der PCA auf dem 2. Faktor mit .616, bei der PFA dagegen mit .458. Erwartungsgemäß ist die Korrelation zwischen den Komponenten mit .556 (PCA) niedriger als die Korrelation zwischen den Faktoren mit .661 (PFA).

Tabelle 6. SPSS-Ausgabe: Komponentenmatrix, Mustermatrix, Strukturmatrix und Faktor-Korrelationsmatrix der zweifaktoriellen PCA mit obliquer Rotation.

Komponentenmatrix			Mustermatrix			Strukturmatrix		
	Komponente			Komponente			Komponente	
	1	2		1	2		1	2
sch1	.698	.366	sch1	.030	.771	sch1	.458	.787
sch2	.565	.279	sch2	.042	.606	sch2	.379	.629
sch3	.611	.382	sch3	-.039	.741	sch3	.373	.720
sch4	.622	.471	sch4	-.126	.843	sch4	.343	.773
sch5	.624	.259	sch5	.098	.616	sch5	.441	.670
sch6	.822	.282	sch6	.191	.748	sch6	.607	.854
dep1	.640	-.266	dep1	.658	.061	dep1	.691	.426
dep2	.757	-.344	dep2	.809	.040	dep2	.831	.490
dep3	.739	-.395	dep3	.850	-.024	dep3	.837	.449
dep4	.571	-.378	dep4	.734	-.096	dep4	.680	.312
dep5	.747	-.223	dep5	.676	.165	dep5	.768	.541
dep6	.690	-.329	dep6	.753	.021	dep6	.764	.439

Komponentenkorrelationsmatrix		
Komponente	1	2
1	1.000	.556
2	.556	1.000

Somit konnte gezeigt werden, dass die Ergebnisse der PCA im Vergleich zur PFA zwar ein ähnliches Muster aufweisen, jedoch die Faktorladungen häufig höher waren als diejenigen der PFA. Dies führt im vorliegenden Fall nicht zu anderen Interpretationen, es kann aber grundsätzlich dazu führen, dass Items fälschlicherweise einer Komponente zugeordnet werden, wenn die Messfehler relativ hoch und damit die Korrelationen zwischen den Items und der entsprechenden Komponente überhöht sind.

## 4.2 Hauptkomponentenanalyse mit drei Faktoren und orthogonaler Rotation

Nachfolgend soll gezeigt werden, welche Ergebnisse resultieren, wenn der Anwender unhinterfragt als Methode der Faktorenextraktion die bereits voreingestellte „Hauptkomponentenanalyse“ auswählt, den verfügbaren Abbruchkriterien (Kaiser-Kriterium, Scree-Test) vertraut sowie die häufig auch unhinterfragt eingesetzte orthogonale Rotation verwendet. Ein solches Vorgehen kommt - wie ausgeführt - relativ häufig in der empirischen Praxis vor.

Die eben vorgenommenen Einstellungen in den Untermenüs können beibehalten werden, jedoch wird nun im Untermenü „Extraktion“ die Option „Basierend auf dem Eigenwert - Eigenwerte größer als eins“ angeklickt, um damit die Anzahl der Faktoren nach dem Kaiser-Kriterium festzulegen (vgl. Abbildung 5 weiter oben). Anders als bisher soll nun eine orthogonale Rotationsmethode gewählt werden. Hierzu wird im Menü *Faktorenanalyse* das Untermenü „Rotation“ ausgewählt und als Rotationsmethode „Varimax“ angeklickt (Abbildung 11).

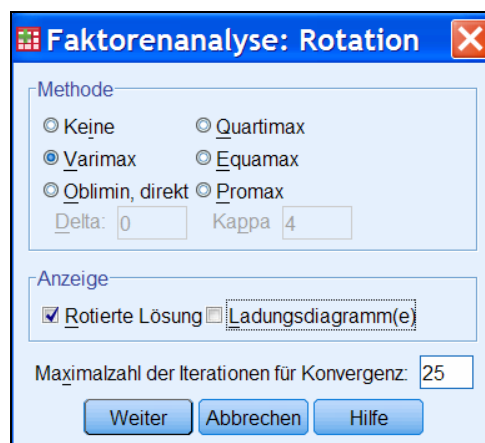


Abbildung 11. Wahl der orthogonalen Rotationsmethode „Varimax“.

Mit „Weiter“ wird das Fenster geschlossen und zum Fenster *Faktorenanalyse* zurückgekehrt. Anklicken von „OK“ startet die Durchführung der Hauptkomponentenanalyse. Die Ergebnisse der Analyse sind wieder im Statistics Viewer in der Datei „Ausgabe1.spv“ unter den anderen Ergebnissen tabellarisch aufgeführt und werden automatisch angezeigt.

Tabelle 7. SPSS-Ausgabe: Kommunalitäten und erklärte Gesamtvarianz der Hauptkomponentenanalyse mit orthogonaler Rotation von drei Faktoren.

Kommunalitäten		
	Anfänglich	Extraktion
sch1	1.000	.660
sch2	1.000	.525
sch3	1.000	.779
sch4	1.000	.715
sch5	1.000	.799
sch6	1.000	.766
dep1	1.000	.413
dep2	1.000	.685
dep3	1.000	.719
dep4	1.000	.663
dep5	1.000	.613
dep6	1.000	.497

Erklärte Gesamtvarianz									
Komponente	Anfängliche Eigenwerte			Summen von quadrierten Faktorladungen für Extraktion			Rotierte Summe der quadrierten Ladungen		
	Gesamt	% der Varianz	Kumulierte %	Gesamt	% der Varianz	Kumulierte %	Gesamt	% der Varianz	Kumulierte %
1	5.390	44.914	44.914	5.390	44.914	44.914	3.253	27.111	27.111
2	1.358	11.320	56.234	1.358	11.320	56.234	2.675	22.296	49.407
3	1.086	9.051	65.286	1.086	9.051	65.286	1.905	15.878	65.286
4	.794	6.617	71.903						
5	.695	5.792	77.695						
6	.554	4.613	82.308						
7	.477	3.971	86.279						
8	.464	3.870	90.149						
9	.410	3.414	93.563						
10	.334	2.782	96.344						
11	.251	2.090	98.435						
12	.188	1.565	100.000						

Wie Tabelle 7 zu entnehmen ist, sind in der PCA unter „Kommunalitäten“ die anfänglichen Kommunalitäten wiederum auf eins gesetzt (Annahme von messfehlerfreien Items), während die Kommunalitäten nach Extraktion von drei Faktoren deutlich geringer als eins, jedoch in der

Regel höher sind als diejenigen der PCA mit nur zwei extrahierten Faktoren (vgl. Tabelle 5). Das Item „sch3“ weist z.B. eine Kommunalität von .779 (PCA, 3 Faktoren) im Vergleich zu .519 (PCA, 2 Faktoren) auf. Unter „Erklärte Gesamtvarianz“ in Tabelle 7 zeigen sich nun höhere kumulierte erklärte Varianzanteile: Es werden in dieser Analyse ca. 65% der Gesamtvarianz durch drei Hauptkomponenten (PCA) erklärt gegenüber ca. 57% durch zwei Hauptkomponenten (PCA, vgl. Tabelle 5, s. weiter oben) bzw. 50% durch drei Faktoren (PFA, vgl. Tabelle 1, s. weiter oben).

Tabelle 8. SPSS-Ausgabe: Komponentenmatrix und orthogonal (Varimax-) rotierte Komponentenmatrix der Hauptkomponentenanalyse mit drei extrahierten Faktoren.

Komponentenmatrix				Rotierte Komponentenmatrix			
	Komponente				Komponente		
	1	2	3		1	2	3
sch1	.684	.399	-.182	sch1	.235	.753	.196
sch2	.582	.290	-.320	sch2	.269	.673	.013
sch3	.599	.265	.591	sch3	.099	.295	.825
sch4	.606	.558	-.189	sch4	.072	.823	.180
sch5	.630	.039	.633	sch5	.268	.137	.842
sch6	.795	.360	-.071	sch6	.314	.744	.338
dep1	.501	-.387	-.110	dep1	.637	.062	.061
dep2	.753	-.343	-.033	dep2	.762	.209	.246
dep3	.745	-.376	-.149	dep3	.806	.228	.135
dep4	.713	-.327	.217	dep4	.669	.096	.453
dep5	.750	-.200	-.101	dep5	.676	.336	.206
dep6	.619	-.217	-.259	dep6	.633	.311	.006

Die Komponentenmatrix (Tabelle 8) mit den Ladungen auf den unrotierten Komponenten lässt sich wie auch bei den anderen Analysen nur schlecht interpretieren, weil alle Items auf der ersten Komponente hoch laden. Die orthogonal rotierte Komponentenmatrix enthält im Vergleich zur Mustermatrix der PAF mit den oblique rotierten Faktoren (vgl. Tabelle 2) keine Einfachstruktur, da mehrere Items nun Sekundärladungen aufweisen. Das Item „dep4“ lädt z. B. zwar recht hoch (.669) auf dem 1. Faktor, auf dem auch die anderen Depressivitätsitems laden, aber es lädt zusätzlich auch noch bedeutsam (.453) auf dem 3. Faktor.

Die Verwendung der Hauptkomponentenanalyse bewirkt wiederum, dass die Faktorladungen insgesamt recht hoch sind. Die orthogonale Rotation führt dazu, dass sich die Faktoren nicht mehr so gut interpretieren lassen wie bei den Analysen mit obliquen Rotation. Es ist unklar, wie der 3. Faktor interpretiert werden sollte, auf dem nicht nur drei Schmerzintensitätsitems

substantiell positiv laden („sch3“, „sch5“ und „sch6“), sondern auch das Depressivitätsitem „dep4“. Hier wäre nicht mehr so einfach zu erkennen, dass es sich bei dem 3. Faktor um einen Methodenfaktor handeln könnte.

## 5 Fazit

Die Demonstration der verschiedenen Analyse-Alternativen sollte zeigen, dass die Wahl der Extraktions- und der Rotationsmethode sehr wesentlich ist. Abhängig von diesen Methoden können recht unterschiedliche Ergebnisse resultieren. Wie unsere Ergebnisse zeigen konnten, sollte man in geeigneten Fällen die Hauptachsenanalyse der Hauptkomponentenanalyse und die oblique Rotation der orthogonalen Rotation vorziehen, um klarer interpretierbare Ergebnisse zu erhalten. Auch die Bestimmung der Anzahl der Faktoren im Datensatz sollte nicht unbesehen dem Programm überlassen werden. Zur Bestimmung der Faktorenanzahl könnte es auch von Interesse sein, verschiedene Abbruchkriterien zu testen, um zu überprüfen, ob eine größere oder kleinere Anzahl an Faktoren zu sinnvolleren und besser interpretierbaren Ergebnissen führt. Neben dem Kaiser-Kriterium und dem Screeplot hätte auch eine Parallelanalyse durchgeführt werden können, die jedoch in SPSS nicht implementiert ist. Die Festlegung der Faktorenanzahl kann aber auch von inhaltlich-theoretischen Überlegungen ausgehen.

Falls bereits präzise Annahmen über die faktorielle Struktur der Daten existieren, und diese Annahmen empirisch geprüft werden sollen, so wäre eine konfirmatorische Faktorenanalyse sinnvoll. Da SPSS konfirmatorische Faktorenanalysen nicht anbietet, müsste dann aber ein spezielles Programm für die Analyse von Strukturgleichungsmodellen verwendet werden.

## 6 Literatur

Bernstein, I. H., Teng, G. (1989). Factoring items and factoring scales are different: Spurious evidence for multidimensionality due to item categorization. *Psychological Bulletin*, 105, 467-477.

Costello, A. B. & Osborne, J. W. (2005). Best practices in exploratory factor analysis: four recommendations for getting the most from your analysis. *Practical Assessment Research & Evaluation*, 10(7). Available online: <http://pareonline.net/getvn.asp?v=10&n=7>

Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, E. J. (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods*, 4, 272-299.



Jonkisz, E. & Moosbrugger, H. (mit Brandt, H.). (2007). Planung und Entwicklung von psychologischen Tests und Fragebogen. In H. Moosbrugger & A. Kelava (Hrsg.), *Testtheorie und Fragebogenkonstruktion* (S. 28-72). Berlin: Springer.

Moosbrugger, H. & Schermelleh-Engel (2007). Exploratorische (EFA) und konfirmatorische Faktorenanalyse (CFA). In H. Moosbrugger & A. Kelava (Hrsg.), *Testtheorie und Fragebogenkonstruktion* (S. 307-324). Berlin: Springer.

Muthén, L. K. & Muthén, B. O. (2007). *Mplus User's Guide* (5th ed.). Los Angeles, CA: Muthén & Muthén.

Nunnally, J. & Bernstein, I. (1994). *Psychometric Theory* (3rd ed.). New York: McGraw-Hill.

Podsakoff, P.M., MacKenzie, S.B., Lee, J.-Y., & Podsakoff, N.P. (2003). Common method bias in behavioral research: A critical review of the literature and recommended remedies. *Journal of Applied Psychology*, 88, 879-903.

Schermelleh-Engel, K. (1995). *Fragebogen zur Schmerzregulation (FSR)*. Frankfurt am Main: Swets Test Services.

Schermelleh-Engel, K., Eifert, G. H., Moosbrugger, H. & Frank, D. (1997). Perceived competence and anxiety as determinants of coping strategies of chronic pain patients. *Journal of Personality and Individual Differences*, 22, 1-10.