

Faktoren- und andere Analysen

Übungen 5

1. **Aufgabe:** Worin besteht der Unterschied zwischen einer PCA und einer Faktorenanalyse (FA)?
 - (a) Die PCA bestimmt nur die Hauptachsen von Ellipsoiden, während die FA auf psychologisch sinnvolle Faktoren (= latente Dimensionen) zielt.
 - (b) Die PCA ist nur eine Anwendung von Theoremen der Linearen Algebra, während die FA ein psychologisches Modell ist.
 - (c) Bei der FA werden gemeinsame latente Variablen (Faktoren) einerseits und spezifische Faktoren bzw. Fehler separat geschätzt, bei der PCA wird eine solche Trennung zunächst nicht vorgenommen
 - (d) Bei der FA wird die multivariate Normalverteilung der Daten angenommen, bei der PCA nicht.

2. **Aufgabe:** Ein gängiges Argument gegen die PCA ist, dass die latenten Dimensionen (Hauptachsen) nicht rotiert werden können, ohne die Unabhängigkeit der latenten Variablen zu zerstören.
 - (a) Macht nichts, unrotiert sind Hauptachsen am schönsten.
 - (b) Da Rotationen beliebig sind, gewinnt man auch nichts, wenn man rotiert.
 - (c) Man kann *entweder* die Faktorwerte *oder* die Ladungen rotieren und dabei die Orthogonalität erhalten (vergl. Satz 3.1 im Skriptum "Einführung in die Hauptkomponenten...")
 - (d) Die Bedeutung von Rotationen wird weithin überschätzt.

3. **Aufgabe:** Gegeben sei eine multiple Regression $\mathbf{y} = X\mathbf{b} + \mathbf{e}$, X die Matrix der Prädiktorvariablen (-> Spalten). Welcher Zusammenhang besteht zwischen der Schätzung $\hat{\mathbf{b}}$ und den Eigenwerten λ_k von X ?
 - (a) Der Vektor $(\lambda_1, \dots, \lambda_n)$ gibt die Richtung an, in die die besten Schätzungen $\hat{\mathbf{y}}$ zeigen.
 - (b) Je größer die λ_k , desto weniger Komponenten von \mathbf{b} müssen geschätzt werden.

- (c) Es gibt keinen Zusammenhang zwischen $\hat{\mathbf{b}}$ und den λ_k , da die Schätzungen $\hat{\mathbf{b}}$ nur von der Voraussagekraft der Prädiktoren abhängen.
- (d) Korrelationen zwischen den Prädiktoren implizieren die Existenz kleiner Eigenwerte, die sich wiederum auf die Varianz der Komponenten von $\hat{\mathbf{b}}$ auswirken.
4. Bei einer PCA-Regression wird die SVD auf die Matrix X der Prädiktoren angewendet, $X = Q\Lambda^{1/2}T'$.
- (a) Die neuen Prädiktoren sind die Spalten von $A = T\Lambda^{1/2}$.
- (b) Die neuen Prädiktoren sind die Spalten von $L = Q\Lambda^{1/2}$.
- (c) Die neuen Prädiktoren sind die Spalten von Q , $\mathbf{u} = \Lambda^{1/2}T'\mathbf{b}$ ist der Vektor der neuen Regressionsgewichte.
5. **Aufgabe:** Eine Faktorenanalyse soll durch eine SVD approximiert werden, $X = Q\Lambda^{1/2}T'$. Welche Bedeutung hat die Matrix $A = T\Lambda^{1/2}$, in welcher Beziehung steht sie zur Matrix R der Korrelationen zwischen den Items?
- (a) $R = A'A$, wobei $\text{diag}(A'A) = \text{diag}(\lambda_1, \dots, \lambda_n)$.
- (b) $R = AA'$, $A'A = \text{diag}(\lambda_1, \dots, \lambda_n)$.
- (c) A ist die Matrix der Ladungen der Variablen. Da sie hypothetisch ist, steht sie in keiner direkten Beziehung zur empirisch gegebenen Matrix R .
- (d) $X = A'A$, da man die Daten aus den Ladungen vorhersagen kann.
6. **Aufgabe:** Es sei $\mathbf{a}_j = (a_{1j}, a_{2j}, \dots, a_{nj})'$ der Vektor der Ladungen der j -ten Variablen auf den latenten Dimensionen.
- (a) $\mathbf{a}'_j\mathbf{a}_j = 1$ für alle j .
- (b) $\mathbf{a}_j\mathbf{a}'_j$ ist als dyadisches Produkt eine orthonormale Matrix, da die \mathbf{a}_j orthonormal sind.
- (c) $\mathbf{a}'_j\mathbf{a}_{j'} = 0$, da die Faktoren orthonormal sind.
- (d) $\mathbf{a}_j = \vec{0}$, wenn die j -te Variable linear abhängig von den übrigen Variablen ist.
7. **Aufgabe:** Sie sollen einen aus dichotomen Items bestehenden Fragebogen analysieren und dazu die latenten Variablen bestimmen, die die befragten Merkmalen unterliegen. Sie berechnen deshalb alle Paare von Items die korrespondierenden ϕ -Koeffizienten.
- (a) ϕ -Koeffizienten sind keine richtigen Korrelationskoeffizienten, da die Antworten nur als entweder falsch (0) oder korrekt (1) kodiert werden, die Merkmale also nicht auf einer Intervallskala gemessen werden.

- (b) $\phi_{ij} = .5$ für alle Variablen $i \neq j$ bedeutet, dass es bei n Items n/s latente Dimensionen gibt.
- (c) Im Fall von $\phi_{ij} \approx .5$ für alle $i \neq j$ gibt es bei hinreichend großem Wert von n nur einen Eigenwert größer als 1.
- (d) Die Randverteilungen $p_i \neq p_j$ für Itempaare ($i \neq j$) sind wesentlich, um irrelevante Schwierigkeitsfaktoren zu vermeiden.

8. **Aufgabe:** Verurteilte Straftäter sollen als entweder rückfallgefährdet oder nicht rückfallgefährdet klassifiziert werden. Für eine Gruppe von Straftätern hat man p Symptome (Prädiktoren) auf Intervallsskalen gemessen, so dass $\mathbf{y} = u_1\mathbf{x}_1 + u_2\mathbf{x}_2 + \dots + u_p\mathbf{x}_p$ und der Wert von \mathbf{y} soll eine möglichst fehlerfreie Klassifikation erlauben. Gesucht sind die "Gewichte" u_k , $k = 1, \dots, p$, um eine optimale Klassifikation zu gewährleisten.

- (a) Der Ansatz ist schon deswegen falsch, weil kein Fehlerterm \mathbf{e} in der Regressionsgleichung für \mathbf{y} auftritt.
- (b) Der Ansatz ist schon deswegen falsch, weil sich menschliches Verhalten nicht berechnen läßt.
- (c) Der Ansatz ist falsch, weil \mathbf{y} notwendig eine (0, 1)-Skala sein müsste (nicht rückfällig, rückfällig), bei kontinuierlichen Prädiktoren \mathbf{x}_k muß aber \mathbf{y} ebenfalls kontinuierlich sein.
- (d) Man muß $\mathbf{u} = (u_1, \dots, u_p)'$ so bestimmen, dass die Varianz der \mathbf{y} zwischen den beiden Gruppen (rückfällig versus nicht rückfällig) maximal wird relativ zur Varianz innerhalb der Gruppen.

9. **Aufgabe:** Es werde noch einmal der Ansatz von Aufgabe 8 betrachtet.

- (a) \mathbf{y} ist eine Linearkombination der \mathbf{x}_k , $1 \leq k \leq p$ und definiert deshalb eine Gerade in einem maximal p -dimensionalen Raum, der linearen Hülle der \mathbf{x}_k . Der Ansatz $\mathbf{y} = \sum_k u_k \mathbf{x}_k$ kann also nur funktionieren, wenn sich das Merkmal Rückfälligkeit auf einer 1-dimensionalen Skala abbilden läßt.
- (b) Man kann die Varianzen-Kovarianzen zwischen den Gruppen in einer Matrix B zusammenfassen, und die Varianzen-Kovarianzen innerhalb der Gruppen in einer Matrix W . Die Maximierung der Varianz "zwischen" relativ zur Varianz "innerhalb"
 - i. bedeutet die Maximierung von $\mathbf{u}'B\mathbf{u}/\mathbf{u}'W\mathbf{u} = \lambda$ bezüglich \mathbf{u} .
 - ii. bedeutet die Bestimmung der \mathbf{u} für $W^{-1}B\mathbf{u} = \lambda\mathbf{u}$.
 - iii. \mathbf{u} als Eigenvektor von $W^{-1}B$ kann nur berechnet werden, wenn $W^{-1}B$ eine symmetrische Matrix ist.
- (c) $W = PDP'$, P die Eigenvektoren von W und $D = \text{diag}(d_1, \dots, d_n)$ die Eigenwerte von W . Dann $W^{-1} = PD^{-1}P'$. Welche Implikationen haben kleine Eigenwerte von W ? Bedenken Sie: $W^{-1} = \sum_k \frac{\mathbf{p}_k \mathbf{p}_k'}{d_k}$.

- i. Kleine Eigenwerte deuten auf Kollinearitäten der Prädiktoren, W^{-1} bedeutet große Varianz der Schätzungen für \mathbf{u} . \square
 - ii. Da $W^{-1}B\mathbf{u} = \lambda\mathbf{u}$ folgt, dass die Komponenten von \mathbf{u} zu klein ausfallen. \square
 - iii. Da $W^{-1}B\mathbf{u} = \lambda\mathbf{u}$ folgt, dass die Komponenten von \mathbf{u} zu groß ausfallen. \square
- (d) Die Anzahl der Lösungen \mathbf{u} für $W^{-1}B\mathbf{u} = \lambda\mathbf{u}$ entspricht dem Rang von $W^{-1}B$.
- i. Da $\mathbf{y} = \sum_k u_k \mathbf{x}_k$ eine Gerade im p -dimensionalen Raum der Prädiktoren definiert, muß *eine* der Lösungen \mathbf{u}_k ausgewählt werden, – man wählt die, deren zugehöriger Eigenwert λ maximal ist. \square
 - ii. Verschiedene Lösungen \mathbf{u}_k können nicht orthogonal sein, da $W^{-1}B$ nicht notwendig symmetrisch ist¹. \square
 - iii. Verschiedene Lösungen \mathbf{u}_k definieren einen orthogonalen Teilraum der linearen Hülle der \mathbf{x}_k mit den Achsen $\mathbf{y}_1, \dots, \mathbf{y}_r$, $r \leq p$. \square

¹Die Eigenvektoren *symmetrischer* Matrizen sind orthogonal.