




The day after tomorrow



05. 02. 2017

Zusammenfassung – Klausur + Frage (Folien)

1. **Vektoren:** Linearkombinationen, Skalarprodukt, dyadisches Produkt:

Linearkombination: $\mathbf{y}, \mathbf{x}_1, \dots, \mathbf{x}_n$ m -dimensional. Dann ist

$$\mathbf{y} = a_1\mathbf{x}_1 + a_2\mathbf{x}_2 + \dots + a_n\mathbf{x}_n = X\mathbf{a}$$

eine Linearkombination der $\mathbf{x}_1, \dots, \mathbf{x}_n$.

Skalarprodukt: $\mathbf{x}'\mathbf{y} = \mathbf{y}'\mathbf{x} = x_1y_1 + x_2y_2 + \dots + x_ny_n \in \mathbb{R}$,

Dyadisches Produkt: $\mathbf{xy}' = (x_iy_j)$ ((m, n) -Matrix).

Fragen:

- (a) Linearkombinationen können nur dann berechnet werden, wenn die Komponenten der Vektoren mindestens Intervallskalenniveau haben!

falsch

- (b) Skalarprodukte können nur dann berechnet werden, wenn sichergestellt ist, dass $\mathbf{x}'\mathbf{y} = \mathbf{y}'\mathbf{x}$

Nonsense

- (c) Das dyadische Produkt ist eine Matrix mit Rang 1!

korrekt

- (d) Das dyadische Produkt kann nur berechnet werden, wenn \mathbf{x} und \mathbf{y} dieselbe Anzahl von Komponenten haben!

falsch

Es gilt $\mathbf{x}'\mathbf{y} = \|\mathbf{x}\|\|\mathbf{y}\|\cos\theta$ nur dann, wenn $\cos\theta > 0$.

falsch

- (e) Zwei Vektoren sind kollinear, wenn sie beide Linearkombinationen derselben Grundvektoren sind.

falsch

- (f) Zwei Vektoren sind kollinear, wenn sie dieselbe Orientierung haben.

korrekt

2. **Lineare Unabhängigkeit:** $\mathbf{x}_1, \dots, \mathbf{x}_n$ sind linear unabhängig dann, wenn $a_1 = \dots = a_n = 0$ für $a_1\mathbf{x}_1 + \dots + a_n\mathbf{x}_n = \vec{0}$. Andernfalls sind sie linear abhängig.

Fragen:

- (a) Die Vektoren $\mathbf{x}_1, \dots, \mathbf{x}_n$ können nur linear abhängig sein, wenn sie miteinander korrelieren.

”falsch” ist falsch, ”korrekt” ist korrekt.

Kommentar: Alle Skalarprodukte (”Korrelationen”) seien gleich Null. Dann sind die Vektoren paarweise orthogonal und damit sind sie auch linear unabhängig (l.u.). Sind sie l.u. so folgt *noch nicht*, dass sie auch paarweise orthogonal sind; es genügt für die lin. Unabhängigkeit, dass $|\cos \theta_{jk}| < 1$ ist, d.h. dass sie nicht alle parallel zueinander sind, dass also $|\cos \theta_{jk} = 1$ *nicht* gilt¹. Der Fall $0 < |\cos \theta_{jk}| < 1$ für alle $\mathbf{x}_j, \mathbf{x}_k$ ist mit linearer Unabhängigkeit kompatibel. Eine ”Korrelation” ($\mathbf{x}'_j \mathbf{x}_k \neq 0$) ist nur *notwendig*, aber nicht *hinreichend* für lineare Abhängigkeit; der Fall $\mathbf{x}'_j \mathbf{x}_k \neq 0$ schließt ja die *Möglichkeit* $\cos \theta_{jk} = 1$ ein. Hinreichend ist $|\cos \theta_{jk}| = 1$ für die lin. Abhängigkeit der beiden Vektoren, nur der Fall $\mathbf{x}'_j \mathbf{x}_k = 0$ schließt lin. Abhängigkeit aus. Dementsprechend *können* sie nur lin. abhängig sein, wenn sie ”korrelieren”, wenn also das Skalarprodukt von Null verschieden ist, sie *müssen* aber nicht lin. abh. sein ...

- (b) Wenn die Vektoren \mathbf{x}_j linear unabhängig sind, sind sie auch orthogonal.

falsch

- (c) Kollineare Vektoren sind linear abhängig.

korrekt

3. **Vektorräume und -teilträume:** Menge V von Vektoren derart, dass jede Linearkombination von Vektoren aus V wieder Element aus V ist (Kurzdefinition!). Ein Teilraum V_t ist eine Teilmenge aus V derart, dass alle Linearkombinationen von Vektoren aus V_t wieder in V_t sind.

Beispiel: Die 5-dimensionalen Vektoren $\mathbf{x}_1, \mathbf{x}_2$ aus dem Vektorraum V aller 5-dimensionalen Vektoren. Teilraum: die lineare Hülle $\mathcal{L}(\mathbf{x}_1, \mathbf{x}_2)$. Alle Linearkombinationen von $\mathbf{x}_1, \mathbf{x}_2$ liegen in einer Ebene des Raums V (die Ebene ist \mathcal{L}). \mathcal{L}^c ist der *Komplementärraum* von \mathcal{L} . Es existiert 5-dimensionaler Vektor $\mathbf{n} \in \mathcal{L}^c$, mit \mathbf{n} orthogonal zu allen $\mathbf{x} \in \mathcal{L}$; dies ist der Normalenvektor für \mathcal{L} .

¹Aus der Logik: Es regnet (p). Dann ist die Straße naß (q), d.h. $p \rightarrow q$. Nun sei die Straße naß. Dann folgt *noch nicht*, dass es regnet (es kann jemand jemand die Strasse naß gespritzt haben). Aber wenn die Strasse *nicht* naß ist, kann es auch nicht regnen, d.h. man kann folgern, dass nicht- q die Aussage nicht- p impliziert. d.h. es gilt $\neg q \rightarrow \neg p$.

Basis, Teilbasis: Eine Menge $\mathcal{B} = \{\mathbf{b}_1, \dots, \mathbf{b}_n\}$ von linear unabhängigen Vektoren aus dem n -dimensionalen Vektorraum derart, dass $V_n = \mathcal{L}(\mathcal{B})$. $\mathcal{B}_r = \{\mathbf{b}_1, \dots, \mathbf{b}_r\}$ mit $r < n$ ist eine Teilbasis, die einen r -dimensionalen Teilraum von V_n aufspannt. Gilt $\mathbf{b}'_j \mathbf{b}_k = 0$ für alle $j \neq k$, $\mathbf{b}'_j \mathbf{b}_j = 1$ für alle j , so ist die Basis eine Orthonormalbasis.

Fragen:

- (a) Jede Menge von Vektoren ist ein Vektorraum, da ja eine Linearkombination von Vektoren wieder ein Vektor ist.

falsch

- (b) Sei M eine Menge n -dimensionaler Vektoren. Die Maximalzahl linear unabhängiger Vektoren $\mathbf{b}_1, \dots, \mathbf{b}_r$, die notwendig ist, um alle Vektoren der lineare Hülle $\mathcal{L}_M = \mathcal{L}(M)$ zu erzeugen, ist die Dimensionalität von \mathcal{L} .

korrekt

- (c) Sei M eine Menge n -dimensionaler Vektoren. Die lineare Hülle $\mathcal{L}(M)$ ist die Menge aller Linearkombinationen der Vektoren aus M .

korrekt

- (d) Die Vektoren einer Basis sind notwendig orthogonal zueinander.

falsch

- (e) Zwei kollineare Vektoren können nicht Elemente einer Basis sein.

korrekt

Kommentar: Die Vektoren $\mathbf{b}_1, \dots, \mathbf{b}_r$ einer Basis *müssen* linear unabhängig sein, denn eine Basis ist als Menge linear unabhängiger Vektoren definiert. Gilt etwa für \mathbf{b}_1 und \mathbf{b}_2 , dass $\mathbf{b}_2 = a\mathbf{b}_1$, $a \in \mathbb{R}$, so sind \mathbf{b}_1 und \mathbf{b}_2 zueinander parallel und damit linear abhängig, können also *nicht beide* Basisvektoren sein, – höchstens einer von ihnen kann Element einer Basis sein.

- (f) Die lineare Hülle von M ist ein Vektorraum (möglicherweise ein Teilraum eines Vektorraumes).

korrekt

- (g) Ein Vektorraum hat beliebig viele Basen.

korrekt

4. **Matrizen:** entstehen durch Aneinander- oder Untereinanderschreiben von Vektoren gleicher Dimensionalität (gleicher Anzahl von Komponenten). Allgemein: es entsteht eine (m, n) -Matrix. Für $m = n$ ist

die Matrix quadratisch. Ist $X = [\mathbf{x}_1, \dots, \mathbf{x}_n]$ eine Matrix mit den \mathbf{x}_j als m -dimensionalen Spaltenvektoren, so ist X' die gestürzte oder transponierte Matrix (jetzt eine (n, m) -Matrix). Gilt $X' = X$, so ist X symmetrisch und damit notwendig auch quadratisch. Operationen: Multiplikationen mit einem Skalar: $aX = (ax_{ij})$, Addition: komponentenweise.

Multiplikation mit einem Vektor: A eine Matrix, \mathbf{x} ein Vektor, $A\mathbf{x} = \mathbf{y}$ ist wieder ein Vektor; \mathbf{y} ist Linearkombination der Spaltenvektoren von A . Voraussetzung: Anzahl der Salten von A gleich der Anzahl der Komponenten von \mathbf{x} .

$\mathbf{x}'A = \mathbf{y}'$; \mathbf{y}' ist ein Zeilenvektor, der sich als Linearkombination der Zeilen von A ergibt. Voraussetzung: Anzahl der Komponenten von \mathbf{x} ist gleich der Anzahl der Zeilen von A .

$A\mathbf{x} = \mathbf{y}$ bzw. $\mathbf{x}'A = \mathbf{y}'$ werden auch Transformationen von \mathbf{x} genannt. A definiert eine Abbildung von Vektoren auf andere Vektoren.

Rotationen: $\mathbf{y} = T\mathbf{x}$, $\|\mathbf{y}\| = \|\mathbf{x}\|$. Dann ist T orthonormal, $T'T = I$. Rotationen lassen die Skalarprodukte invariant: $\mathbf{x} = T\mathbf{u}$, $\mathbf{y} = T\mathbf{v}$, so ist $\mathbf{x}'\mathbf{y} = \mathbf{u}'T'T\mathbf{v} = \mathbf{u}'\mathbf{v}$.

Fragen:

- (a) Es sei A eine (m, n) -Matrix und es gelte $\mathbf{y} = A\mathbf{x}'$. Macht diese Behauptung Sinn?

geht gar nicht, total falsch

- (b) Es gelte $\mathbf{y} = \mathbf{x}'A$; ist \mathbf{y} eine Zeilen- oder ein Spaltenvektor?

$\mathbf{x}'A$ muß ein Zeilenvektor sein, also muß \mathbf{y} ein Zeilenvektor sein; dann aber müsste es \mathbf{y}' heißen.

- (c) $\mathbf{y} = A\mathbf{x}$.

\mathbf{x} muß n -dimensional sein

korrekt

\mathbf{x} muß m -dimensional sein

falsch

Multiplikation einer Matrix mit einer anderen: $C = AB$. Voraussetzung: Anzahl der Spalten von A gleich Anzahl der Zeilen von B . Die Spalten von C sind Linearkombinationen der Spaltenvektoren von A , die Zeilenvektoren sind Linearkombinationen der Zeilen von B .

Es sei A eine quadratische Matrix, λ eine Diagonalmatrix gleicher Dimensionalität. $A\lambda = B$; die Spaltenvektoren von B sind die län-

genskalierten Spaltenvektoren von A . $\Lambda A = B$: die Zeilenvektoren von B sind die längenskalierten Zeilenvektoren von A .

Fragen:

- (a) Anzahl der Zeilen von A muß gleich der Anzahl der Spalten von B sein sein.

falsch

- (b) Die Spalten von C sind Linearkombinationen der Spalten von A .

korrekt

- (c) Die Zeilen von C sind Linearkombinationen der Zeilen von A .

falsch

Rang einer (m, n) -Matrix: Der Spaltenrang ist die Anzahl der m -dimensionalen, linear unabhängigen Vektoren \mathbf{b}_j , die benötigt werden, die Spaltenvektoren von A als Linearkombinationen der \mathbf{b}_j darzustellen. Der Zeilenrang ist die Anzahl von linear unabhängigen, n -dimensionalen Vektoren \mathbf{c}_k , die benötigt werden, die Zeilenvektoren als Linearkombinationen der \mathbf{c}_k darzustellen. Es gilt: Zeilenrang = Spaltenrang = Rang.

Es gilt $\text{rg}(A) \leq \min(m, n)$. Sei $n = \min(m, n)$. Gilt $\text{rg}(A) = n$, so hat A "vollen Rang".

Es sei $C = AB$. Dann gilt $\text{rg}(C) \leq \min(\text{rg}(A), \text{rg}(B))$.

Der Rang der Matrix $\mathbf{xy}' = (x_i y_j)$ ist gleich 1. Denn

$$\begin{aligned} \mathbf{xy}' &= \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} (y_1, y_2, y_3) = \begin{pmatrix} x_1 y_1 & x_1 y_2 & x_1 y_3 \\ x_2 y_1 & x_2 y_2 & x_2 y_3 \end{pmatrix} \\ &= \left(y_1 \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}, y_2 \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}, y_3 \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \right) \end{aligned}$$

Das dyadische Produkt ist eine Matrix, deren Spaltenvektoren alle kollinear sind.

Fragen:

- (a) Der Zeilenrang ist gleich dem Spalterang unter der Voraussetzung, dass die Matrix A sich in der Form $A = UV$ darstellen läßt, wobei U eine (m, r) - und V eine (r, n) -Matrix ist.

falsch

- (b) Der Rang kann höchstens gleich dem Spaltenrang sein, weil es stets weniger Variable als Fälle gibt.

falsch

- (c) Der Rang r einer Matrix ist nur definiert, wenn zumindest einige der Zeilen- und Spaltenvektoren linear unabhängig sind. falsch
- (d) r bezieht sich nur auf die Spaltenvektoren von A , da die Spalten einer Matrix stets die Variablen repräsentieren. falsch
- (e) r ist stets größer als die kleinere der beiden Zahlen m und n . falsch
- (f) Zeilen- gleich Spaltenrang $\leq \min(m, n)$. korrekt
- (g) Die (m, n) -Matrix X habe den Rang $r \leq \min(m, n)$. Dann existiert eine (m, r) -Matrix U und eine (r, n) -Matrix V derart, dass $X = UV$. korrekt
- (h) Die (m, n) Matrix X habe den Rang r . Dann existiert eine (r, m) -Matrix U und eine (n, r) -Matrix V derart, dass $X = UV$. falsch
- (i) Die (m, n) Matrix X habe den Rang r . Dann existiert eine (m, r) -Matrix U und eine (r, n) -Matrix V derart, dass $X = UV$. korrekt

5. **Quadratische Formen:** M sei eine symmetrische (n, n) -Matrix, \mathbf{x} n -dimensionaler Vektor. $\mathbf{x}'M\mathbf{x} = k$ heißt 'Quadratische Form':

$$\mathbf{x}'M\mathbf{x} = \sum_{i=1} m_{ii}x_i^2 + 2 \sum_{i < j} m_{ij}x_i x_j = k$$

$\mathcal{E}_x = \{\mathbf{x} | \mathbf{x}'M\mathbf{x} = k\}$ ist ein Ellipsoid.

$\mathcal{E}_y = \{\mathbf{y} | \mathbf{y}'\Lambda\mathbf{y} = k\}$, $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$ ist ein *achsenparalleles* Ellipsoid (keine Regression).

Es gelte $\mathbf{x} = T\mathbf{y}$, T eine Rotation. Dann folgt $\mathbf{x}'M\mathbf{x} = \mathbf{y}'T'MT\mathbf{y} = k$ und $T'MT = \Lambda$. Es folgt $TT'MT = MT = T\Lambda$. Für den Spaltenvektor \mathbf{t} aus T folgt $M\mathbf{t} = \lambda\mathbf{t}$, d.h. die \mathbf{t} sind *Eigenvektoren* von M , λ die zugehörigen Eigenwerte.

Es sei \mathbf{t} ein Eigenvektor von M . M kann als Transformationsmatrix aufgefasst werden: $M\mathbf{t} = \lambda\mathbf{t}$ heißt, dass M die Orientierung von \mathbf{t} invariant läßt.

Da T eine Rotationsmatrix ist, ist T orthonormal. Es folgt, dass die Eigenvektoren einer symmetrischen Matrix orthonormal sind.

Auch nicht-symmetrische Matrizen haben Eigenvektoren, die aber nicht notwendig auch orthogonal sind.

Es sei $\text{rg}(M) = r$, $M' = M$. Dann hat M r von Null verschiedene Eigenwerte. Alle Eigenwerte sind größer/gleich Null, wenn M positiv semidefinit ist. M ist positiv semidefinit, wenn M von der Form $M = X'X$ ist, X eine (m, n) -Matrix (z.B. X ist eine Datenmatrix).

Kovarianz- und Korrelationsmatrizen sind positiv semidefinit, haben also nur Eigenwerte größer/gleich Null.

Satz von Courant-Fischer: Der Rayleigh-Quotient $\lambda = \frac{\mathbf{x}'A\mathbf{x}}{\mathbf{x}'\mathbf{x}}$, A symmetrisch, wird maximal, wenn $\lambda = \lambda_1$ der erste (= maximale) Eigenwert von A ist und $\mathbf{x} = \mathbf{t}_1$ der zugehörige Eigenvektor ist.

Fragen:

- (a) $\mathbf{x}'M\mathbf{x} = k$ ist eine quadratische Form nur dann, wenn $M' = M$, d.h. wenn M symmetrisch ist. korrekt
- (b) Gilt $\mathbf{x}'M\mathbf{x} = k$, so ist \mathbf{x} ein Eigenvektor von M . falsch
- (c) \mathbf{x} ist nur dann ein Eigenvektor von M , wenn $M\mathbf{x} = \lambda\mathbf{x}$ gilt korrekt
- (d) Es sei $M' = M$ eine symmetrische (n, n) -Matrix. Unter einer quadratischen Form versteht man
 - i. Die Matrix $M^2 = m \cdot M$. falsch
 - ii. Die Gleichung $M\mathbf{x} = \|\mathbf{x}\|^2$: falsch
 - iii. Den Ausdruck $\mathbf{x}'M\mathbf{x} = k \in \mathbb{R}$, weil

iv. $\mathbf{x}'M\mathbf{x} = \sum_i m_{ii}x_i^2 + 2 \sum_{i<j} m_{ij}x_ix_j = k$ und die Summe der Exponenten der Vektorkomponenten stets gleich 2 ist.

korrekt

v. stets ein Ellipsoid definiert.

falsch

(e) $M = C$ sei eine Kovarianzmatrix. Dann ist C nur dann eine Transformationsmatrix, wenn $M\mathbf{x} = \mathbf{y}$ eine Transformation des Vektors \mathbf{x} in den Vektor \mathbf{y} ist.

falsch

(f) T sei eine (n, n) -Matrix derart, dass $\mathbf{y} = T\mathbf{x}$ und $\|\mathbf{x}\| = \|\mathbf{y}\|$.

i. T ist orthonormal, so dass $T'T = I$.

korrekt

ii. T kann einen Rang kleiner als n haben.

falsch

iii. T läßt die Skalarprodukte für transformierte Vektoren invariant.

korrekt

(g) Es sei M symmetrisch und es gelte $\mathbf{x}'M\mathbf{x} = \mathbf{y}'\Lambda\mathbf{y} = k$, $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$. Weiter gelte $\mathbf{x} = T\mathbf{y}$ mit $\|\mathbf{x}\| = \|\mathbf{y}\|$. Dann gilt

i. $T'MT = \Lambda$

korrekt

ii. $MT = T\Lambda$, T Matrix der Eigenvektoren, Λ Diagonalmatrix der Eigenwerte von M

korrekt

iii. $MT = T\Lambda$ nur dann, wenn $T = I$ die Einheitsmatrix.

falsch

iv. $MT = T\Lambda$ nur dann, wenn M den Rang ($\text{rg}(M) = n$) hat,

falsch

v. Hat M den Rang $r < n$, können alle Eigenwerte größer als Null sein.

falsch

6. **Bestimmung einer Basis für eine Matrix X :** Finde eine Matrix S derart, dass $XS = L$, L orthogonal, und es existiert eine Matrix T' mit $X = LT'$. Die Spaltenvektoren von L sind Basisvektoren für die Spaltenvektoren von X .

Es gibt zwei Möglichkeiten:

- (a) Definiere S als Rotationsmatrix. Dann folgt, dass $S = T$ die Matrix der Eigenvektoren von $X'X$ ist und $\lambda_1 = \mathbf{L}'_1\mathbf{L}_1$ die maximale Varianz der Koordinaten der Fälle auf erster latenter Achse hat.
- (b) Definiere die Spaltenvektoren \mathbf{L}_k von L so, dass $\mathbf{L}'_1\mathbf{L}_1$ maximale Varianz hat. Dann folgt, dass $S = T'$ die Eigenvektoren von $X'X$ enthält und eine Rotation der Spaltenvektoren \mathbf{x}_j erzeugen.

Der Fall (a): Ansatz: $XS = L$, L orthogonal, S eine Rotation.

$L'L = \Lambda = \text{diag}(\lambda_1, \dots, \lambda_n) = S'(X'X)S$. S Rotation impliziert $S'S = I$ die Einheitsmatrix, und dann

$SS'(X'X)S = S\Lambda \Rightarrow S = T$, T Matrix der Eigenvektoren, Λ die Matrix der Eigenwerte.

Welche Orientierung der $L = [\mathbf{L}_1, \dots, \mathbf{L}_n]$ liefert maximale Varianz der Koordinaten (Projektionen) der Fälle auf die Achsen?

Satz von Courant-Fischer:

$$\frac{\mathbf{s}'(X'X)\mathbf{s}}{\mathbf{s}'\mathbf{s}} = \frac{\mathbf{L}'\mathbf{L}}{\|\mathbf{s}\|^2} = \lambda = \max$$

wenn $\lambda = \lambda_1$ der erste Eigenwert und $\mathbf{s}/\|\mathbf{s}\| = \mathbf{t}_1$ der korrespondierende erste Eigenvektor ist, so dass $\|\mathbf{t}_1\|^2 = 1$.

Also $S = T$ die Matrix der orthonormalen Eigenvektoren, Λ Eigenwerte.

Der Fall (b): Ansatz: $XS = L$, $\mathbf{L}'_1\mathbf{L}_1$ soll maximal sein, $\mathbf{L}'_2\mathbf{L}_1 = 0$ (Orthogonalität). Dann wieder $S'(X'X)S = \Lambda$, und der Satz von Courant-Fischer liefert die Aussage, dass $S = T$ die Matrix der Eigenvektoren von $X'X$ und Λ die zugehörige Matrix der Eigenwerte; die Orthonormalität der Eigenvektoren impliziert, dass $S = T$ eine Rotationsmatrix ist.

Fragen:

- (a) Der Ansatz $X = LT'$ mit orthogonaler Matrix L macht nur Sinn, wenn die Komponenten von X keine Messfehler enthalten, da er eine rein algebraische Aussage ist.

falsch

- (b) Die Annahme, dass L orthogonal sein soll, impliziert, dass T die Matrix der Eigenvektoren von $X'X$ ist.

korrekt

(c) Man muß annehmen, dass in der Forderung $XS = L$ die Matrix S eine Rotation repräsentiert.

falsch

(d) Der Ansatz $X = LT'$ ist doof, da trivial.

falsch

(e) Der Ansatz $X = LT'$ ist sinnlos, da das Psychische nicht algebraisch sein kann.

falsch

7. Singularwertzerlegung (SVD):

$$\mathbf{L}'_j \mathbf{L}_j = \|\mathbf{L}_j\|^2 = \lambda_j \Rightarrow \|\mathbf{L}_j\| \sqrt{\lambda_j},$$

Normalisierung der \mathbf{L}_j : Multiplikation mit $1/\sqrt{\lambda_j} = \lambda_j^{-1/2} \Rightarrow Q = L\Lambda^{-1/2} \Rightarrow Q\Lambda^{1/2} = L$.

$$X = LT' = Q\Lambda^{1/2}T' = \text{SVD}.$$

Fragen:

(a) Die PCA ist eine Anwendung der SVD

korrekt

(b) Die SVD gilt nur, wenn $X = LT'$ postuliert werden kann.

falsch

(c) Die SVD gilt nur bei intervallskalierten Messwerten.

falsch

8. Approximation Faktorenanalyse (PCA): L enthält die Koordinaten der Fälle, – aber man ist im Allgemeinen an den Variablen interessiert. Die SVD erlaubt zwei Interpretationen:

$$X = Q\Lambda^{1/2}T' = \begin{cases} LT', & \text{Fokus auf Fälle} \\ QA', & A = T\Lambda^{1/2} \text{ "Ladungen", Fokus auf Variablen} \end{cases}$$

A : Zeilen = Variablen, Spalten = latente Dimensionen, a_{jk} Ladung der j -ten Variablen auf der k -ten Dimension.

Warum nicht anders herum? Q ist (m, n) – m Fälle, n latente Variablen. $X = QA' \Rightarrow x_{ij} = \tilde{\mathbf{q}}'_i \tilde{\mathbf{a}}_j$, $\tilde{\mathbf{q}}_i$ i -ter Zeilenvektor von Q , $\tilde{\mathbf{a}}_j$ j -ter Zeilenvektor von $A = j$ -ter Spaltenvektor von A' , und j steht für die j -te Variable. $\tilde{\mathbf{a}}_j = (a_{j1}, a_{j2}, \dots, a_{jn})$, und die Komponenten a_{jk} stehen für die k -te Dimension bei der j -ten Variablen.

Es sei $X = Z$ (spaltenstandardisiert). Dann ist $R = \frac{1}{m}Z'Z$ die Matrix der Korrelationen, $Z = QA' \Rightarrow R = \frac{1}{m}AQ'QA' = \frac{1}{m}AA'$. Korrelation zwischen den Variablen u und v : $r_{uv} = \tilde{\mathbf{a}}_u \tilde{\mathbf{a}}_v = \sum_{k=1}^n a_{uk} a_{vk}$

$r_{jj} = 1 = \sum_{k=1}^n a_{jk}^2 \Rightarrow$ Endpunkte der Ladungsvektoren für die Variablen liegen auf n -dimensionaler Hyperkugel, z.B. auf einem Kreis, wenn es nur 2 latente Dimensionen gibt.

Aus $Z = QA'$ folgt $Z' = AQ' \Rightarrow ZQ = A$, d.h. $a_{jk} = \mathbf{z}'_j \mathbf{q}_k$, d.h. die Ladung a_{jk} der j -ten Variablen auf der k -ten latenten Dimension entspricht einer Korrelation zwischen der j -ten Variablen und der k -ten Dimension.

Fragen:

- (a) Die Komponenten des Spaltenvektors \mathbf{a}_k sind die Ladungen der Variablen auf der k -ten latenten Dimension.
korrekt
- (b) Der Zeilenvektor $\tilde{\mathbf{a}}_j$ enthält die Ladungen der j -ten Variablen auf den latenten Dimensionen.
korrekt
- (c) Die Summe der Quadrate der Komponenten von $\tilde{\mathbf{a}}_j$ (d.h. $\|\tilde{\mathbf{a}}_j\|^2$, ist stets gleich 1.
korrekt
- (d) $\|\mathbf{a}_k\|^2 = \lambda_k =$ der k -te Eigenwert von $Z'Z$.
korrekt
- (e) $\|\mathbf{L}_k\|^2 = \lambda_k$
korrekt

Abschätzung der Anzahl latenter Dimensionen: Üblicherweise der Scree-Test. Aber mit Vorsicht anwenden: Auch wenn die Variablen alle statistisch unabhängig sind, sind die empirischen Korrelationen zufällig (um Null) verteilt es kann mehrere Eigenwerte deutlich größer als 1 geben (Kaiser-Kriterium). Deswegen erst Sphärizitäts-Test anwenden!!! (Der nimmt die multivariate Normalverteilung der Daten an, aber diese Annahme ist i.A. approximativ gerechtfertigt.)

Fragen:

- (a) Das Kaiser-Kriterium erlaubt stets eine korrekte Abschätzung der bedeutungsvollen Eigenwerte.
falsch
- (b) Der Sphärizitätstest ist vernachlässigbar, da nur bei multivariat normalverteilten Variablen anwendbar.
falsch, zumindest nicht ganz korrekt
- (c) Exponentiell abfallende Eigenwerte im Scree-Plot legen stochastische Unabhängigkeit der Variablen nahe.
So einfach ist das nicht! Aber manchmal ist es so.

Biplot: Die latenten Dimensionen sind dieselben für Fälle und Variablen. Dieser Sachverhalt legt nahe, sowohl die Fälle wie die Variablen in ein und demselben Plot zu repräsentieren. Schließlich ist x_{ij} bzw. z_{ij} (Messwert des i -ten Falls bei der j -ten Variablen) durch das Skalarprodukt

$$z_{ij} = q_{i1}a_{j1} + q_{i2}a_{j2} + \dots + q_{in}a_{jn}$$

gegeben. Dabei sind aber die q_{ik} standardisierte Variablen, die a_{jk} dagegen skalierte Variablen: t_{jk} mit $\sqrt{\lambda_k}$ multipliziert. Möglichkeit:

$$Z = Q\Lambda^{1/2}T' = (Q\Lambda^{1/4})(\Lambda^{1/4}T') = LA' \text{ mit}$$

$L = Q\Lambda^{1/4}$, $A = T\Lambda^{1/4}$. Man erhält eine Repräsentation der Beziehungen zwischen Fällen und Variablen.

Fragen:

- (a) Ein Biplot ist die Darstellung von Fällen und Variablen bzw. von Zeilen- und Spaltenkategorien in einem einzigen Plot.

korrekt

- (b) Der Biplot ist nur möglich, wenn die Daten auf einer Absolutskala (Häufigkeiten, vergl. Korrespondenzanalyse) gemessen werden.

falsch

- (c) Der Biplot ist eine mentale Verirrung der Statistiker, da im realen Leben jeder fall ganzheitlich erfasst werden muß.

falsch

Rotationen: $Z = Q\Lambda^{1/2}T' = QSS'\Lambda^{1/2}T' = Q\Lambda^{1/2}SS'T'$.

Fragen:

- (a) Bei der PCA machen Rotationen der Achsen keinen Sinn, weil dann die Unabhängigkeit der latenten Variablen verloren geht (PCA: die orientierte Konfiguration der Fälle wird in ein achsenparalleles Koordinatensystem transformiert, – Nullregression!)

falsch

- (b) Man kann entweder die Fälle, repräsentiert in der Matrix L , rotieren, verliert dann aber die Beziehung zu den Variablen oder umgekehrt: man rotiert die Variablen, hat aber keinen Bezug mehr zu den Fällen. In beiden Fällen macht der Biplot keinen Sinn mehr.

korrekt

9. **Faktorenanalyse (FA):** Modell $\frac{1}{\sqrt{m}}Z = FA' + \mathbf{e}$. Dann

$R = \frac{1}{m}Z'Z = AA' + V$, $V = \text{diag}(v_1^2, \dots, v_n^2)$. $h_j^2 = 1 - v_j^2$ ist die Kommunalität für die j -te Variable, das ist die durch die gemeinsamen Faktoren (common factors) erklärte Varianz der j -ten Variablen.

$$AA' = T\Lambda T' = R_h, R = AA' + V.$$

$$F = ZT\Lambda^{-1/2} = ZR_h^{-1}A = [\mathbf{F}_1, \dots, \mathbf{F}_p]$$

\mathbf{F}_k Hauptfaktoren.

$$\lambda_1 + \dots + \lambda_p = h_1^2 + \dots + h_p^2.$$

Fragen:

- (a) Vorteil der FA ist die explizite Schätzung der Varianz der Variablen (entspricht der Reliabilität im Sinne der Theorie psychometrischer Tests, bei der PCA wird $\sigma_j^2 = 1$ gesetzt für alle j).

korrekt

- (b) Ein Vorteil der FA ist die begriffliche Trennung von *common factors* und *unique factors*.

korrekt

- (c) Der Nachteil der FA ist die Schwierigkeit, die Kommunalität zu schätzen.

korrekt

Rolle der Skalen: Insbesondere (0,1)-Daten, $r_{uv} = \phi_{uv}$ der Phi-Koeffizient. Variiert nur im vollen Bereich $[-1, +1]$, wenn $p_u = p_v$.

Fragen:

- (a) $p_u = p_v = .5$ impliziert $\phi_{uv} = .5$

falsch

- (b) $p_u = p_v = .5 \Rightarrow -1 \leq \phi \leq 1$

korrekt

- (c) $p_u \neq p_v$ unvermeidlich, wenn die Grundquoten für die 1-Antworten unterschiedlich sind (unterschiedlich schwierige Items).

korrekt

- (d) $p_u \neq p_v$ impliziert "triviale" Schwierigkeitsfaktoren.

korrekt

10. **Korrespondenzanalyse:** (Correspondence Analysis (CA)) Man geht von 2-dimensionalen Häufigkeitstabellen aus. Sind die gegebenen Tabellen höherdimensional, so kann man sie u. U. durch Neben- oder Untereinanderschreiben in 2-dimensionale Tabellen verwandeln (vergl. die Selbstmorddaten).

$$\chi^2_{(m,n)} = \sum_{i=1}^m \sum_{j=1}^n \frac{(n_{ij} - n_{i+}n_{+j})^2}{n_{i+}n_{+j}}$$

Definiere

$$x_{ij} = \frac{n_{ij} - n_{i+}n_{+j}}{\sqrt{n_{i+}n_{+j}}}$$

$$X = (x_{ij}), \text{ SVD } X = U_0 \Lambda^{1/2} V_0'$$

Skalierung: $f_{ik} = u_{ik} \sqrt{\lambda_k / r_i}$, $g_{jk} = v_{jk} \sqrt{\lambda_k / c_j}$. $r_i = \sum_j n_{ij} / N$, $c_j = \sum_i n_{ij} / N$.

χ^2 -Distanzen:

$$d_{ii'} = \sqrt{\sum_{k=1}^p (f_{ik} - f_{i'k})^2}$$

$$d_{jj'} = \sqrt{\sum_{k=1}^p (g_{jk} - g_{j'k})^2}$$

Relation j -te Zeilenkategorie, k -te Spaltenkategorie:

$$\mathbf{f}_i \mathbf{g}_j = \|\mathbf{f}_i\| \|\mathbf{g}_j\| \cos \theta_{jk}$$

Fragen:

- (a) Die CA ist eine PCA der Häufigkeiten in einer Kontingenztafel. falsch
- (b) Die CA beruht auf einer Anwendung der SVD auf die Matrix der standardisierten Residuen x_{ij} (wie oben definiert). korrekt
- (c) Die Reskalierung der Matrizen U_0 und V_0 liefert den Bezug zu unabhängigen χ^2 -Anteilen. korrekt
- (d) Zwischen den Fällen und den Variablen kann für die Interpretation im Biplot eine Distanz berechnet werden. falsch

11. **PCA-Regression:**

$$\mathbf{y} = b_1 \mathbf{x}_1 + b_2 \mathbf{x}_2 + \dots + b_p \mathbf{x}_p + \mathbf{e} = X \mathbf{b} + \mathbf{e}$$

Schätzung von \mathbf{b} : $\hat{\mathbf{b}} = (X'X)^{-1}X'\mathbf{y}$.

$$(X'X)^{-1} = V\Lambda^{-1}V'$$

Eigenschaften der Schätzungen:

$$\mathbb{E}(\hat{\mathbf{b}}) = \mathbf{b}, \text{Var}(\hat{\mathbf{b}}) = \sigma^2(X'X)^{-1} = \sigma^2 \sum_{k=1}^p \frac{\mathbf{v}_k \mathbf{v}_k'}{\lambda_k}$$

$$\text{Var}(\hat{\mathbf{b}}) = \sum_{j=1}^p \frac{v_{kj}^2}{\lambda_j}$$

Korrelationen zwischen den Prädiktoren

\Rightarrow kleine Eigenwerte

\Rightarrow große Varianz der Schätzungen!

PCA-Regression:

$$X = Q\Lambda^{1/2}T' \Rightarrow \mathbf{y} = Q\Lambda^{1/2}T'\mathbf{b} + \mathbf{e}$$

$$\mathbf{u} = \Lambda^{1/2}T'\mathbf{b} \Rightarrow \mathbf{y} = Q\mathbf{u} + \mathbf{e}$$

$$\hat{\mathbf{u}} = (Q'Q)^{-1}Q'\mathbf{y} = Q'\mathbf{u} + Q'\mathbf{e}.$$

Fragen:

(a) Substantielle (dh nicht nur zufällig von Null abweichende) Korrelationen zwischen den Prädiktoren erhöhen die Varianz der Schätzungen der Regressionsgewichte.

korrekt

(b) Die Spaltenvektoren von Q (neue Prädiktoren) entsprechen nicht notwendig Variablen in der Realität.

korrekt

Zur letzten Frage: die Spaltenvektoren von Q sind Linearkombinationen der gemessenen Variablen; insofern sind die Q -Variablen Mischungen von realen Variablen. Ob diese Mischungen unabhängig von den gemessenen Variablen gefunden werden können, ist letztlich eine empirische Frage. Man mache sich klar: Es gibt unendlich viele Linearkombinationen der $\mathbf{x}_1, \dots, \mathbf{x}_n$, – warum sollen sie alle in der Natur vorkommen?

12. **Klassifikation:** $\mathbf{y} = u_1\mathbf{x}_1 + \dots + u_p\mathbf{x}_p$.

Gesucht: $\mathbf{u} = (u_1, u_2, \dots, u_p)'$ derart, dass Fälle, die zu verschiedenen Klassen gehören, maximal getrennt werden.

Komponenten des unbekanntes Vektors \mathbf{y} sind Koordinaten der Fälle.

Komponenten sollen so angeordnet werden, dass die Variation der Koordinaten *innerhalb* der Gruppen bzw. Kategorien klein ist im Vergleich zur Variation der Mittelwerte der Komponenten für die einzelnen Gruppen bzw. Kategorien:

$$\lambda = \frac{QS_{zw}(\mathbf{u})}{QS_{inn}(\mathbf{u})} = \max!$$

$$QS_{zw}(\mathbf{u}) = \mathbf{u}'B\mathbf{u}, \quad QS_{inn} = \mathbf{u}'W\mathbf{u}$$

$$\lambda(\mathbf{u}) = \frac{\mathbf{u}'B\mathbf{u}}{\mathbf{u}'W\mathbf{u}} \Rightarrow W^{-1}B\mathbf{u} = \lambda\mathbf{u}$$

Der Rang von $W^{-1}B$ ist gleich der Anzahl der Eigenvektoren \mathbf{u}_k mit zugehörigen Eigenwerten λ_k . Die $\mathbf{y}_k = X\mathbf{u}_k$ sind orthogonal.

Das Verfahren funktioniert insbesondere dann gut, wenn die Konfigurationen der Fälle in den einzelnen Kategorien bzw. Gruppen Ellipsoide sind; sie sollten sich möglichst wenig überlappen. Dann können die Gruppen linear getrennt werden.

Bei korrelierten Prädiktoren ergeben sich ähnliche Probleme wie bei der multiplen Korrelation. Ausweg: Regularisierte Diskriminanzanalyse und verwandte Verfahren (nicht in dieser Vorlesung behandelt).

Fragen:

- (a) Lineare Trennbarkeit der Kategorien bedeutet, dass die Konfigurationen der Fälle in den einzelnen Kategorien Ellipsoide sind, – die Daten also multivariat normalverteilt sind.
falsch
- (b) Man benötigt minimal so viele Fälle, wie es Prädiktoren gibt, um zu stabilen Schätzungen der \mathbf{u} zu kommen.
falsch²
- (c) Im Ansatz $\mathbf{y} = X\mathbf{u}$ gibt es keinen Fehlerterm \mathbf{e} . Da stets Messfehler auftreten, ist der Mangel eines Fehlerterms ein Konstruktionsfehler der Diskriminanzanalyse.
falsch
- (d) Es sei $\bar{\mathbf{y}}_k$ der mittlere Vektor für die k -te Klasse. $|\mathbf{y} - \bar{\mathbf{y}}_k|$ entspricht einer Mahalanobis-Distanz.
korrekt
- (e) Die Diskriminanzanalyse entspricht nicht dem Bayesschen Ansatz, nach dem die Wahrscheinlichkeit $P(K|D)$, einen Fall auf der Basis D von Prädiktorwerten der Kategorie zuzuordnen, durch $P(K|D) = P(D|K)P(K)/P(D)$ gegeben ist, so dass a priori Wahrscheinlichkeiten $P(K)$ für die Kategorien eingehen.
Das macht nichts, da die $P(K)$ sowieso subjektive Größen sind.
falsch

13. **Logistische Regression:** Man kann nach Maßgabe des Bayesschen Theorems klassifizieren:

$$P(K|D) = \frac{P(K \cap D)}{P(D)} = \frac{P(D|H)P(H)}{P(D|H)P(H) + P(D|\neg H)P(\neg H)}$$

K Kategorie, D Daten (Prädiktoren). Division der rechten Seite durch $P(D|H)P(H)$:

$$P(H|D) = \frac{1}{1 + \frac{P(D|\neg H)P(\neg H)}{P(D|H)P(H)}} = \frac{1}{1 + q}, \quad q = \frac{P(D|\neg H)P(\neg H)}{P(D|H)P(H)}$$

Es ist $q = e^{\log q}$. Nimmt man an, dass die Prädiktoren multivariat normalverteilt sind, so ergibt sich nach ein wenig Rechnerei

$$\log q = b_1 \mathbf{x}_1 + \dots + b_p \mathbf{x}_p$$

²mindestens 4- bis 5-mal so viele!

und man erhält die

$$P(H|D) = \frac{1}{1 + e^{b_1 \mathbf{x}_1 + \dots + b_p \mathbf{x}_p}}$$

Nach ein wenig Rechnen erhält man

$$\frac{P(H|D)}{1 - P(H|D)} = e^{b_1 \mathbf{x}_1 + \dots + b_p \mathbf{x}_p}$$

und die Logits

$$\log \frac{P(H|D)}{1 - P(H|D)} = b_1 \mathbf{x}_1 + \dots + b_p \mathbf{x}_p$$

Schätzung der b_j : Maximum-Likelihood-Methode.