

Multivariate Analysemethoden

Diskriminanzanalyse

*Günter Meinhardt
Johannes Gutenberg Universität Mainz*

Discriminant Function Analysis (DFA)

Ziele

- Maximale **Trennung von Gruppen** auf einem gegebenem Set von p Meßvariablen.
- Auffinden von **latenten Diskriminanzfunktionen**, die sukzessive maximale Gruppentrennung gewährleisten.
- In der Regel: Auffinden eines **niedrig dimensionierten Diskriminanzraumes**, in dem die Gruppen separierbar sind.
- **Case-Classification** in optimalen, niedrig dimensionierten Räumen.
- Bestimmung von **Klassifikationsfunktionen** für Case-Classification.

Voraussetzung

- **Gleiche (homogene) Varianz-Kovarianz Matrizen** in allen Gruppen.
- Testungen der Gruppenunterschiede (Centroide), sowie der Homogenität der Σ_j - Matrizen erfordern die Gültigkeit der **multivariaten Normalverteilung**.

Ansatz

- Optimierung des Verhältnisses der Quadratsummen für „between“ und „within“ Group Varianz.
- Lösung über **Eigenwertzerlegung** einer aus **B** und **W** Komponenten zusammengesetzten Matrix.


Anwendung

- Diagnostische Trennung schwierig zu trennender Gruppen.
- Bestimmung kritischer diagnostischer Variablen / Reduktion auf relevante diagnostische Variablen in multivariaten Klassifikationen.
- Konstruktion von Algorithmen zur Mustertrennung (Pattern recognition machines) und Bildklassifikation (bildgebende Verf.).
- Qualitätskontrolle und Evaluation von Versuchs- und Kontrollgruppen in multivariaten Designs.

Nachteile

- **Restriktion** gleicher Varianz-Kovarianz Matrizen in allen Gruppen.
- **Case-Classification**: Klassifikation im Diskriminanzraum hat gegenüber MDC und Bayesian Classifier keine wesentlichen Vorteile (außer Sparsamkeit) und läuft auf dasselbe hinaus.


2D-Beispiel



Problem

- Klassifiziere anhand von Fühlerlänge (X_1) und Flügelänge (X_2) möglichst eindeutig in Stechmücke (c_1) und Blindmücke (c_2).
- Das geht mit einem Kriteriumswert auf jeder einzelnen Variable X_1 und X_2 offenbar nicht.

2D-Beispiel



Lösung:

Eine **lineare Kriteriumsfunktion** teilt den Variablenraum in 2 Gebiete: Oberhalb **Stachmücke** (c_1), unterhalb **Blindmücke** (c_2).

$$x_2 = b + ax_1$$


Somit folgt die Klassifikationsfunktion

$$g(x_1, x_2) = \begin{cases} c_1, & \text{wenn } x_2 - ax_1 > b \\ c_2, & \text{wenn } x_2 - ax_1 \leq b \end{cases}$$

Einfache Lösung:

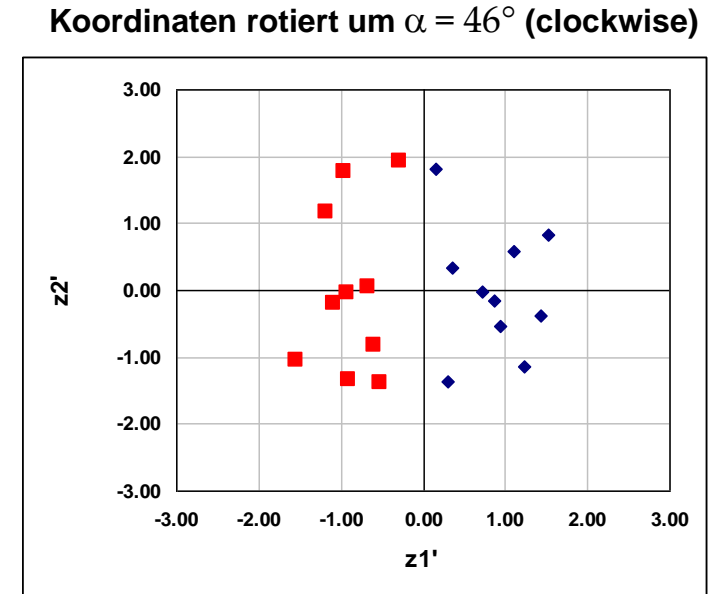

Zuerst die Daten im Nullpunkt zentrieren und dann um **den optimalen Winkel α** drehen !

Zentrierung & Rotation



Die Varianz zwischen den Gruppen wird auf der Achse x'_1 maximiert, und x'_2 steht senkrecht x'_1 . Eine Parallele zu x'_2 liefert das optimale Trennkriterium.

z-Standard




Diskriminanzfunktion

- Die neue x- Achse z_1' ist die **Diskriminanzfunktion** y . Auf ihr läßt sich ein Kriterium zur optimalen Trennung beider Gruppen finden.
- Da eine Drehoperation auf die Diskriminanzfunktion geführt hat, ist sie darstellbar als eine **Linearkombination der alten Koordinaten**:

$$y = b_1 x_1 + b_2 x_2$$

y: Linear- kombination



$$\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} \begin{pmatrix} z_1 \\ z_2 \end{pmatrix} = \begin{pmatrix} z'_1 \\ z'_2 \end{pmatrix} \quad \rightarrow \quad \begin{aligned} z_1 \cos \alpha - z_2 \sin \alpha &= z'_1 \\ z_1 \sin \alpha + z_2 \cos \alpha &= z'_2 \end{aligned}$$

Da $y = z'_1$ gilt



$$y = b_1 z_1 + b_2 z_2$$

mit $b_1 = \cos \alpha$ und $b_2 = -\sin \alpha$

Koeffizienten von y

Das Auffinden der Koeffizienten b_1 und b_2 ist also identisch mit dem Problem, den optimalen Drehwinkel α zu bestimmen. Hierfür braucht man ein Kriterium der gewünschten maximalen Trennung, und die Lösung des dahinter stehenden **Maximierungsproblems**.

Rotation zur y - Funktion



Klassifikation

- Case-Classification durch einfachen Vergleich mit dem Kriterium y_0 .
- Prüfung des Gruppenunterschieds mit einem einfachen t - Test auf y .
- Voraussetzung: homogene Varianz-Kovarianz Matrizen.

Kriterium der Maximierung

Maximiert wird das Verhältnis der Quadratsummen für die Variation auf y zwischen Gruppen QS_B und der Variation innerhalb Gruppen QS_W .

$$\Gamma(\vec{b}) = \frac{QS_{Between}}{QS_{Within}} = \frac{\text{erklärte Variation}}{\text{nicht erklärte Variation}} = \max$$

(Wähle die Koeffizienten b so, daß $\Gamma(b)$ maximal wird)

Quadratsummenzerlegung

Wie in der [Varianzanalyse](#) gilt die Quadratsummenzerlegung

$$QS_{Total} = QS_{Between} + QS_{Within}$$

mit

$$QS_{Total} = \sum_{l=1}^K \sum_{i=1}^{n_l} (y_{il} - \bar{y})^2$$

K = Anzahl Gruppen
 n_l = Umfang Gruppe l

$$QS_{Between} = \sum_{l=1}^K n_l (\bar{y}_l - \bar{y})^2$$

$$QS_{Within} = \sum_{l=1}^K \sum_{i=1}^{n_l} (y_{il} - \bar{y}_l)^2$$

Kenngrößen der Güte

γ : (Eigenwert der Maximierung)

$$\gamma = \frac{\text{erklärte Var}}{\text{nicht erklärte Var}} \quad \rightarrow \quad \frac{\gamma}{1+\gamma} = \frac{QS_B}{QS_B + QS_W} = \frac{\text{erklärte Var}}{\text{Gesamt Var}}$$

$$c^2 = \frac{\gamma}{1+\gamma} = \frac{\text{erklärte Var}}{\text{Gesamt Var}}, \quad c = \text{"Kanonische Korrelation"}$$

$$\Lambda = \frac{1}{1+\gamma} = \frac{\text{nicht erklärte Var}}{\text{Gesamt Var}}, \quad \Lambda = \text{"Wilk's Lambda"}$$

Offenbar gilt

$$c^2 + \Lambda = \frac{QS_B}{QS_B + QS_W} + \frac{QS_W}{QS_B + QS_W} = 1$$

χ^2 - Test der Trennleistung

$$\chi^2 = - \left(N - \frac{m + K}{2} - 1 \right) \ln \Lambda$$

K = Anzahl Gruppen
 $N = \sum n_l = n_1 + n_2 + \dots + n_K$
 m = Anzahl Variablen

ist χ^2 verteilt mit $m(K-1)$ Freiheitsgraden

➔ Die Trennleistung wird mit einem χ^2 Test auf Signifikanz getestet

Gepoolte Varianz der y - Funktion

Die Varianz innerhalb der Gruppen wird zu einer gepoolt:

$$\hat{s}_y^2 = \frac{\sum_l QS_{W(l)}}{df_l} = \frac{QS_{W(1)} + QS_{W(2)} + \dots + QS_{W(K)}}{(n_1 - 1) + (n_2 - 1) + \dots + (n_K - 1)} = \frac{\sum_l n_l \cdot s_l^2}{\sum_l (n_l - 1)}$$

Normierte y - Funktion

Damit wird die Varianz der Diskriminanzfunktion auf 1 normiert:

$$\tilde{y} = \frac{y}{\hat{s}_y} \quad \rightarrow \quad \text{var}(\tilde{y}) = \left(\frac{1}{\hat{s}_y} \right)^2 \cdot \text{var}(y) = \frac{\hat{s}_y^2}{\hat{s}_y^2} = 1$$

MANOVA Additivität der Variation

Es gilt:

$$\mathbf{M} = \mathbf{B} + \mathbf{W}$$

← *Within Group QS und Kreuzprodukte*
 ↑ *Between Group QS und Kreuzprodukte*
 ↗ *Totale QS und Kreuzprodukte*

Kompakte Darstellung

$$\sum_l \sum_i (\mathbf{x}_{il} - \bar{\mathbf{x}})(\mathbf{x}_{il} - \bar{\mathbf{x}})^t = \sum_l n_l (\bar{\mathbf{x}}_l - \bar{\mathbf{x}})(\bar{\mathbf{x}}_l - \bar{\mathbf{x}})^t + \sum_l \sum_i (\mathbf{x}_{il} - \bar{\mathbf{x}}_l)(\mathbf{x}_{il} - \bar{\mathbf{x}}_l)^t$$

Hierin sind die \mathbf{x} Vektoren mit m Komponenten (Variablen):

$$\mathbf{x}_{il} = \begin{pmatrix} x_{il1} \\ x_{il2} \\ \vdots \\ x_{ilm} \end{pmatrix} \quad \bar{\mathbf{x}}_l = \begin{pmatrix} \bar{x}_{l1} \\ \bar{x}_{l2} \\ \vdots \\ \bar{x}_{lm} \end{pmatrix} \quad \bar{\mathbf{x}} = \begin{pmatrix} \bar{x}_1 \\ \bar{x}_2 \\ \vdots \\ \bar{x}_m \end{pmatrix}$$

Regel

Die Matrizen \mathbf{B} und \mathbf{W} werden als inneres Produkt (Zeilen- mal Spalten) der Variablen-Vektoren aufgebaut und dann über Fälle und Gruppen summiert.

B-Matrix (p=2 Vars)

Treatment (Group) Quadratsummen & Kreuzprodukte

$$\mathbf{B} = \begin{matrix} & \begin{matrix} x_1 & x_2 \end{matrix} \\ \begin{pmatrix} TQS_1 & TQS_{12} \\ TQS_{12} & TQS_2 \end{pmatrix} & \begin{matrix} x_1 \\ x_2 \end{matrix} \end{matrix}$$

Komponenten

$$TQS_1 = n_1 (\bar{x}_{11} - \bar{x}_1)^2 + n_2 (\bar{x}_{21} - \bar{x}_1)^2$$

$\begin{matrix} \nearrow & \nwarrow \\ \text{Group} & \text{Var} \end{matrix}$

$$TQS_2 = n_1 (\bar{x}_{12} - \bar{x}_2)^2 + n_2 (\bar{x}_{22} - \bar{x}_2)^2$$

$$TQS_{12} = n_1 (\bar{x}_{11} - \bar{x}_1)(\bar{x}_{12} - \bar{x}_2) + n_2 (\bar{x}_{21} - \bar{x}_1)(\bar{x}_{22} - \bar{x}_2)$$

W-Matrix (p=2 Vars)

Within group Quadratsummen & Kreuzprodukte (gepoolt)

$$W = \begin{pmatrix} WQS_1 & WQS_{12} \\ WQS_{12} & WQS_2 \end{pmatrix} \begin{matrix} x_1 \\ x_2 \end{matrix}$$

Komponenten

$$WQS_1 = \sum_{i=1}^{n_1} (x_{i11} - \bar{x}_{11})^2 + \sum_{i=1}^{n_2} (x_{i21} - \bar{x}_{21})^2$$

\uparrow \uparrow
Group **Var**

$$WQS_2 = \sum_{i=1}^{n_1} (x_{i12} - \bar{x}_{12})^2 + \sum_{i=1}^{n_2} (x_{i22} - \bar{x}_{22})^2$$

$$WQS_{12} = \sum_{i=1}^{n_1} (x_{i11} - \bar{x}_{11})(x_{i12} - \bar{x}_{12}) + \sum_{i=1}^{n_2} (x_{i21} - \bar{x}_{21})(x_{i22} - \bar{x}_{22})$$

W aus gepoolten Σ - Matrizen

$$W = n_1 \Sigma_1 + n_2 \Sigma_2 + \dots + n_K \Sigma_K$$

mit Σ_l der Varianz-Kovarianz Matrix in Gruppe l .

Max-Bedingung

$$\Gamma = \frac{QS_B}{QS_W} = \frac{\mathbf{v}^t \mathbf{B} \mathbf{v}}{\mathbf{v}^t \mathbf{W} \mathbf{v}} \quad \text{mit} \quad \mathbf{v} = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix}$$

ist die Darstellung der Quadratsummen der Diskriminanzfunktion y über die quadratische Form mit dem Vektor der b - Koeffizienten

Maximierung

$$\max(\Gamma) \Big|_{\mathbf{v}} \quad \text{führt auf} \quad \frac{\partial \Gamma}{\partial \mathbf{v}} = 0 \quad \text{und dies auf}$$

$$(\mathbf{B} - \gamma \mathbf{W}) \mathbf{v} = \mathbf{0} \quad \text{nach Vormultiplizieren mit } \mathbf{W}^{-1} \text{ auf}$$

$$(\mathbf{W}^{-1} \mathbf{B} - \gamma \mathbf{I}) \mathbf{v} = \mathbf{0}$$

was eine Eigenwertbedingung für die Matrix $\mathbf{A} = \mathbf{W}^{-1} \mathbf{B}$ ist.

\mathbf{v} ist Eigenvektor von \mathbf{A}

\mathbf{A} ist eine $m \times m$ Matrix, also ist \mathbf{v} allgemein m -stellig. Zu jedem Eigenwert γ ungleich 0 existiert ein Eigenvektor \mathbf{v} . Die Stellen des \mathbf{v} Vektors sind die gesuchten Diskriminanzkoeffizienten jeder Diskriminanzfunktion.

Eigenvektoren \mathbf{v}

$$\mathbf{v}_1^t = (b_{11} \quad b_{21} \quad \dots \quad b_{m1}) \dots \mathbf{v}_m^t = (b_{1k} \quad b_{2k} \quad \dots \quad b_{mk})$$

mit $k = \min(K - 1, m)$

Anzahl von \mathbf{v}

Es gibt so viele Eigenvektoren \mathbf{v} , und damit auch so viele Diskriminanzfunktionen, wie die kleinere Zahl aus der Anzahl der Gruppen-1 und der Anzahl der Variablen, m .

**Normierung
 der
 Diskriminanz-
 funktion y**

Die gepoolte Varianz einer Diskriminanzfunktion erhält man direkt aus der quadratischen Form

$$\hat{s}_y^2 = \frac{1}{N - K} \mathbf{v}^t \mathbf{W} \mathbf{v}$$

Damit kann y direkt nach der Bestimmung normiert werden, indem man

$$\tilde{\mathbf{v}} = \frac{1}{\hat{s}_y} \mathbf{v} \quad \text{als Koeffizientenvektor der normierten Diskriminanzfunktion verwendet:} \quad \tilde{y} = \frac{1}{\hat{s}_y} \sum_{j=1}^m b_j x_j$$

**Nicht
 standardisiert**

Sind die Variablen x nicht standardisiert worden, kommt eine additive Konstante hinzu:

$$y = b_0 + \sum_{j=1}^m b_j x_j \quad \text{mit} \quad b_0 = -\sum_{j=1}^m b_j \bar{x}_j$$

Mehrere DFs (Diskriminanz- raum)

- Sukzessive extrahierte Diskriminanzfunktionen klären absteigend geordnet Diskriminationsvarianz auf.
- Es gilt für die anteilige Varianzaufklärung durch Funktion y_i

$$\frac{QS_{B(i)}}{QS_W + QS_B} = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \dots + \lambda_i + \dots + \lambda_k}$$

- Alle Diskriminanzfunktionen können auf signifikante Diskriminationsleistung getestet werden (s. z.B. Bortz, 2005, S. 610)
- Alle sukzessiven Diskriminanzfunktionen sind orthogonal.
- Das Prinzip der Aufteilung der Diskriminationsvarianz auf sukzessiv nach Beitrag geordnete und orthogonale Diskriminanzfaktoren ist mit der PCA gut vergleichbar.
- Daraus ergibt sich auch ein vergleichbarer [Anwendungszusammenhang](#) (s.n.)

Anwendung

- Ermittlung relevanter Diskriminationsvariablen.
- Wenn man an einer Reduktion der kritischen Variablen interessiert ist.
- Wenn der Vergleich / die Trennung von Populationen im Vordergrund steht: Benutzt man k -Diskriminanzfunktionen als Eingabedaten für MANOVA oder T^2 Kontraste, wird eine maximale Trennschärfe erreicht, die größer ist als die der k einzelnen Variablen des Sets für $k < m$.

Einzelfall-Klassifikation

- Kann im Diskriminanzraum mit denselben Verfahren (MDC, QCR, Bayesian Classifier) wie üblich gemacht werden.
- Die Einzelfall-Klassifikation wird im vollständigen Diskriminanz-**nicht besser** als im Variablenraum mit allen Variablen. Vorteile ergeben sich nur, wenn weniger Variablen verwendet werden sollen.
- Die DFA gestattet die Herleitung einfacher Klassifikationsfunktionen mit denen die Fallklassifikation besonders ökonomisch ist.