


## Vergleich mehrerer multiv. Mittelwerte

### Es gibt 3 verschiedene Situationen:

- Vergleich von Mittelwerten aus gepaarten Stichproben aus wiederholten Messungen  
(kann durch Änderung der  $T^2$ -Statistik gelöst werden)
- Vergleich von Mittelwerten aus zwei Stichproben von verschiedenen Grundgesamtheiten  
(kann durch Änderung der  $T^2$ -Statistik gelöst werden)
- Vergleich mehrerer Mittelwerte aus Stichproben von verschiedenen Grundgesamtheiten  
(MANOVA)




## Gepaarte Stichproben

Angenommen es werden  $p$  Variablen am gleichen Objekt zweimal gemessen, z.B.:

- Kontroll Bedingungen vs. Behandlung
- Vor Einnahme eines Medikamentes und nach der Einnahme
- Qualitätskontrolle:  
Zwei Labore untersuchen die gleichen Objekte und ihre Ergebnisse werden verglichen.

**Wichtig:**

**Es handelt sich immer um die gleiche Instanz, an der gemessen bzw. beobachtet wurde.**



## Notation

$j = 1, \dots, n$  Beobachtungen:

$X_{1j1}$  = Variable 1 unter Behandlung 1

$\vdots$

$X_{1jp}$  = Variable  $p$  unter Behandlung 1

---

$X_{2j1}$  = Variable 1 unter Behandlung 2

$\vdots$

$X_{2jp}$  = Variable  $p$  unter Behandlung 2

---


Die *neue Stichprobe*,  $\mathbf{D}_j = (D_{j1}, D_{j2}, \dots, D_{jp})'$ , ergibt sich aus

$$D_{j1} = X_{1j1} - X_{2j1}$$

$$D_{j2} = X_{1j2} - X_{2j2}$$

$\vdots$

$$D_{jp} = X_{1jp} - X_{2jp}$$



...


Sei  $\delta$  der Mittelwert der (Differenz der) Grundgesamtheit, und angenommen die Stichprobe  $\mathbf{D}_j$  ist unabhängig  $N_p(\delta, \Sigma_d)$  verteilt, dann ist der Test zum Niveau  $\alpha$  für  $H_o : \delta = \mathbf{0}$  gegen  $H_A : \delta \neq \mathbf{0}$  verwerfe  $H_o$  falls:

$$T^2 = n\bar{\mathbf{D}}' \mathbf{S}_d^{-1} \bar{\mathbf{D}} > \frac{(n-1)p}{n-p} \mathcal{F}_{p, n-p}(\alpha)$$

Damit ist die  $100(1 - \alpha)\%$  Konfidenz Region für  $\delta$  die Menge aller  $\delta$  die

$$(\bar{\mathbf{D}} - \delta)' \mathbf{S}_d^{-1} (\bar{\mathbf{D}} - \delta) \leq \frac{(n-1)p}{n(n-p)} \mathcal{F}_{p, n-p}(\alpha)$$

erfüllt.




## Konfidenzregionen

Die simultanen Konfidenz Intervalle für die einzelnen Mittelwertdifferenzen,  $\delta_i$ ,  $i = 1, \dots, p$  sind gegeben durch:

$$\bar{D}_i \pm \sqrt{\frac{(n-1)p}{n-p} \mathcal{F}_{p, n-p}(\alpha)} \sqrt{\frac{s_{D_i}^2}{n}}$$

und, die Bonferroni  $100(1 - \alpha)\%$  simultanen Konfidenz Intervalle sind gegeben durch:


$$\bar{D}_i \pm t_{n-1}\left(\frac{\alpha}{2p}\right) \sqrt{\frac{s_{D_i}^2}{n}}$$





## Beispiel: Wasserproben

- Gemessen wurden
  - Sauerstoffgehalt (SG)
  - Schwebeteilchen (ST)
- 2 Labore
  - staatlich
  - privat
- Frage:  
Sind die Messergebnisse als Ganzes unterschiedlich?

Probe	SG	ST	SG	ST	SG	ST
1	6	27	25	15	-19	12
2	6	23	28	13	-22	10
3	18	64	36	22	-18	42
4	8	44	35	29	-27	15
5	11	30	15	31	-4	-1
6	34	75	44	64	-10	11
7	28	26	42	30	-14	-4
8	71	124	54	64	17	60
9	43	54	34	56	9	-2
10	33	30	29	20	4	10
11	20	14	39	21	-19	-7




...



$$\bar{\mathbf{D}} = \begin{bmatrix} -9.36 \\ 13.27 \end{bmatrix} \quad \mathbf{S}_d = \begin{bmatrix} 199.3 & 88.3 \\ 88.3 & 418.6 \end{bmatrix}$$

$$T^2 = 11[-9.36 \quad 13.27] \begin{bmatrix} 0.0055 & -0.0012 \\ -0.0012 & 0.0026 \end{bmatrix} \begin{bmatrix} -9.36 \\ 13.27 \end{bmatrix} = 13.6$$

$$2 \times 10/9 \mathcal{F}_{2,9}(0.05) = 9.47 \Rightarrow \text{Verwerfe } H_0.$$




# MANOVA

## Situation:

- **Daten**
  - $g$  Stichproben der Größe  $n_1, \dots, n_g$
  - $p$  Variablen.
- **Grundgesamtheit**
  - $g$  Grundgesamtheiten
  - verschiedene Mittelwerte  $(\mu_1, \dots, \mu_g)$
  - gleiche Covarianz  $(\Sigma)$
  - multivariat normalverteilt.

## Mögliche Anwendungen

1. Statistische Versuchsplanung mit multipler Response
2. Klassifikationsprobleme



## Rückblick: univariate ANOVA

Zufallsstichproben  $X_{l1}, X_{l2}, \dots, X_{ln_l}$  aus  $N(\mu_l, \sigma^2)$ ,  $l = 1, \dots, g$ . Frage: Sind die Gruppenmittelwerte alle gleich, d.h.  $\mu_1 = \mu_2 = \dots = \mu_g$ . Daraus folgt die Parametrisierung:

$$X_{lj} = \mu + \tau_l + e_{lj}$$

mit der Nebenbedingung  $\sum_{l=1}^g n_l \tau_l = 0$ , und der Nullhypothese:


$$H_0 : \tau_1 = \tau_2 = \dots = \tau_g = 0$$

Das Modell wird angepasst, indem jede Beobachtung in ihre Komponenten zerlegt wird:

$$X_{lj} = \bar{X} + (\bar{X}_l - \bar{X}) + (X_{lj} - \bar{X}_l), \quad j = 1, \dots, n_l; \quad l = 1, \dots, g$$

und die Quadratsummen für jede Komponente berechnet werden:

$$\sum_{l=1}^g \sum_{j=1}^{n_l} (X_{lj} - \bar{X})^2 = \sum_{l=1}^g n_l (\bar{X}_l - \bar{X})^2 + \sum_{l=1}^g \sum_{j=1}^{n_l} (X_{lj} - \bar{X}_l)^2$$



...

## ANOVA Tabelle


Quelle	QS	Fg
Modell (zwischen)	$SS_Z$	$g - 1$
Residuen (innerhalb)	$SS_I$	$\sum_{l=1}^g n_l - g$
Gesamt	$SS_G$	$\sum_{l=1}^g n_l - 1$

Dann testen wir die Hypothese

$H_0 : \tau_1 = \tau_2 = \dots = \tau_g = 0$  gegen  $H_A : \text{nicht alle gleich } 0,$

mittels

$$F = \frac{SS_Z / (g - 1)}{SS_I / (\sum_{l=1}^g n_l - g)} \sim \mathcal{F}_{g-1, \sum n_l - g}(\alpha)$$



## Multivariate ANOVA

Als Modellgleichung ergibt sich


$$\mathbf{X}_{lj} = \boldsymbol{\mu} + \boldsymbol{\tau}_l + \mathbf{e}_{lj}$$

wobei  $\mathbf{X}_{lj}$ ,  $\mathbf{e}_{lj}$   $n_l \times p$  Matrizen sind, und  $\boldsymbol{\mu}$ ,  $\boldsymbol{\tau}_l$   $p$ -dim. Vektoren.  
Die Datenzerlegung ist dann:

$$\mathbf{X}_{lj} = \bar{\mathbf{X}} + (\bar{\mathbf{X}}_l - \bar{\mathbf{X}}) + (\mathbf{X}_{lj} - \bar{\mathbf{X}}_l), \quad j = 1, \dots, n_l; \quad l = 1, \dots, g$$

Die Quadratsummenzerlegung ist:

$$\begin{aligned} \sum_{l=1}^g \sum_{j=1}^{n_l} (\mathbf{X}_{lj} - \bar{\mathbf{X}})(\mathbf{X}_{lj} - \bar{\mathbf{X}})' &= \underbrace{\sum_{l=1}^g n_l (\bar{\mathbf{X}}_l - \bar{\mathbf{X}})(\bar{\mathbf{X}}_l - \bar{\mathbf{X}})'}_{\mathbf{B}_{p \times p}} \\ &+ \underbrace{\sum_{l=1}^g \sum_{j=1}^{n_l} (\mathbf{X}_{lj} - \bar{\mathbf{X}}_l)(\mathbf{X}_{lj} - \bar{\mathbf{X}}_l)'}_{\mathbf{W}_{p \times p}} \end{aligned}$$



# MANOVA Tabelle und Test

- MANOVA Tabelle

Quelle	QS	Fg
Modell (zwischen)	<b>B</b>	$g - 1$
Residuen (innerhalb)	<b>W</b>	$\sum_{l=1}^g n_l - g$
Gesamt	<b>B + W</b>	$\sum_{l=1}^g n_l - 1$


- Hypothesentest

$$H_0 : \tau_1 = \dots = \tau_l = \mathbf{0}$$

Problem: Hier werden nun Matrizen und keine einzelnen Werte verglichen. Diese Matrizen entsprechen  $p$ -d Varianz Ellipsen. Als mögliche Teststatistik wird meist Wilks' lambda benutzt:

$$\Lambda^* = \frac{|W|}{|B + W|}$$

Wenn  $\Lambda^*$  zu klein ist, wird  $H_0$  verworfen.




## Verteilung von Wilks $\Lambda$

# Vars	# Gruppen	Verteilung von $\Lambda^*$
1	$\geq 2$	$\left( \frac{\sum n_l - g}{g-1} \right) \left( \frac{1 - \Lambda^*}{\Lambda^*} \right) \sim \mathcal{F}_{g-1, \sum n_l - g}$
2	$\geq 2$	$\left( \frac{\sum n_l - g - 1}{g-1} \right) \left( \frac{1 - \sqrt{\Lambda^*}}{\sqrt{\Lambda^*}} \right) \sim \mathcal{F}_{2(g-1), 2(\sum n_l - g - 1)}$
$\geq 1$	2	$\left( \frac{\sum n_l - p - 1}{p} \right) \left( \frac{1 - \Lambda^*}{\Lambda^*} \right) \sim \mathcal{F}_{p, \sum n_l - p - 1}$
$\geq 1$	3	$\left( \frac{\sum n_l - p - 2}{p} \right) \left( \frac{1 - \sqrt{\Lambda^*}}{\sqrt{\Lambda^*}} \right) \sim \mathcal{F}_{2p, 2(\sum n_l - p - 2)}$

Wenn  $\sum n_l = n$  groß ist, kann  $H_0$  auf einem Signifikanz Niveau von  $\alpha$  verworfen werden, falls gilt:

$$-(n - 1 - (p + g)/2) \ln \left( \frac{|W|}{|B + W|} \right) > \chi_{p(g-1)}^2(\alpha)$$



## Wilks $\Lambda$ über Eigenwerte


$\Lambda^*$  lässt sich auch alternativ darstellen über

$$\Lambda^* = \prod_{i=1}^{\min(p, g-1)} \frac{1}{1 + \lambda_i}$$

wobei  $\lambda_i$ ;  $i = 1, \dots, \min(p, g-1)$  die Eigenwerte von  $W^{-1}B$  sind.

Es gilt:

- Da Wilks' lambda auf Determinanten der Matrizen **W** und **B** basiert, werden im wesentlichen Volumina von Ellipsen verglichen.
- Eine andere Methode diese Volumina zu vergleichen ist über die Längen der Hauptachsen, d.h. Eigenwerte.




## MANOVA: Beispiel

Daten  $\mathbf{X}$ , mit  $p = 2$  Dimensionen,  $g = 3$  Gruppen der Größe  $n_1 = 3, n_2 = 2, n_3 = 3$ .

$$\mathbf{X} = \begin{pmatrix} [9] & [6] & [9] \\ [3] & [2] & [7] \\ [0] & [2] & \\ [4] & [0] & \\ [3] & [1] & [2] \\ [8] & [9] & [7] \end{pmatrix}$$

$$\text{und } \bar{\mathbf{X}} = \begin{bmatrix} 4 \\ 5 \end{bmatrix}, \bar{\mathbf{X}}_1 = \begin{bmatrix} 8 \\ 4 \end{bmatrix}, \bar{\mathbf{X}}_2 = \begin{bmatrix} 1 \\ 2 \end{bmatrix}, \bar{\mathbf{X}}_3 = \begin{bmatrix} 2 \\ 8 \end{bmatrix}.$$

$$\begin{aligned} \mathbf{B} &= \sum_{l=1}^g n_l (\bar{\mathbf{X}}_l - \bar{\mathbf{X}})(\bar{\mathbf{X}}_l - \bar{\mathbf{X}})' \\ &= 3 \cdot \left( \begin{bmatrix} 8 \\ 4 \end{bmatrix} - \begin{bmatrix} 4 \\ 5 \end{bmatrix} \right) \left( \begin{bmatrix} 8 \\ 4 \end{bmatrix} - \begin{bmatrix} 4 \\ 5 \end{bmatrix} \right)' + \dots \\ &= 3 \begin{bmatrix} 4 \\ -1 \end{bmatrix} [4 \quad -1] + \dots \\ &= 3 \begin{pmatrix} 16 & -4 \\ -4 & 1 \end{pmatrix} + \dots + 3 \begin{pmatrix} 4 & -6 \\ -6 & 9 \end{pmatrix} = \begin{pmatrix} 78 & -12 \\ -12 & 48 \end{pmatrix} \end{aligned}$$



## Beispiel (cont.)

$$\begin{aligned}
 \mathbf{W} &= \sum_{l=1}^g \sum_{j=1}^{n_l} (\mathbf{X}_{lj} - \bar{\mathbf{X}}_l)(\mathbf{X}_{lj} - \bar{\mathbf{X}}_l)' \\
 &= \left( \begin{bmatrix} 9 \\ 3 \end{bmatrix} - \begin{bmatrix} 8 \\ 4 \end{bmatrix} \right) \left( \begin{bmatrix} 9 \\ 3 \end{bmatrix} - \begin{bmatrix} 8 \\ 4 \end{bmatrix} \right)' + \dots + \left( \begin{bmatrix} 3 \\ 8 \end{bmatrix} - \begin{bmatrix} 2 \\ 8 \end{bmatrix} \right) \left( \begin{bmatrix} 3 \\ 8 \end{bmatrix} - \begin{bmatrix} 2 \\ 8 \end{bmatrix} \right)' + \dots \\
 &= \begin{bmatrix} 1 \\ -1 \end{bmatrix} [1 \quad -1] + \dots + \begin{bmatrix} 1 \\ 0 \end{bmatrix} [1 \quad 0] + \dots \\
 &= \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix} + \dots + \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} + \dots \\
 &= \begin{pmatrix} 6 & 6 \\ 6 & 14 \end{pmatrix} + \dots + \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix} = \begin{pmatrix} 10 & 1 \\ 1 & 24 \end{pmatrix}
 \end{aligned}$$

$$\Lambda^* = \frac{|\mathbf{W}|}{|\mathbf{B} + \mathbf{W}|} = \frac{10 \cdot 24 - 1 \cdot 1}{88 \cdot 72 - (-11 \cdot -11)} = 0.0385$$

verwerfe  $H_0$  bei einem Niveau von  $\alpha = 0.01$  wegen

$$\left( \frac{\sum n_l - g - 1}{g - 1} \right) \left( \frac{1 - \sqrt{\Lambda^*}}{\sqrt{\Lambda^*}} \right) = 8.19 > 7.01 = \mathcal{F}_{4,8}(0.01)$$