


- **Aineisto:** 22 satunnaisesti valittua karitsaa
- **Koeryhmä:**  $i = 1, \dots, 11$ ; uusi ruokavalio
- **Kontrolliryhmä:**  $i = 11, \dots, 22$ ; vanha ruokavalio
- **Kysymys:** Onko ruokavalioiden välillä eroa ja riippuuko mahdollinen ero ruokinta-ajan pituudesta, joka vaihteli 50 ja 90 päivän välillä?
- **Selitettävä muuttuja  $y$ :** Karitsan painon nousu koeajan aikana (mitattuna nauloissa)
- **Selittävät muuttujat:** Koeajan pituus  $x$  sekä ryhmää osoittavat indikaattorimuuttujat  $d_1$  (koeryhmä) ja  $d_2$  (kontrolliryhmä)



**Kuva 5.1.** Karitsojen painonnouluun ( $y$ ) ja koeajan pituuteen ( $x$ ) liittyvä aineisto koeryhmän (+) ja kontrolliryhmän (o) mukaan luokiteltuna sekä kummallekin ryhmälle PNS:llä estimoidut regressiosuorat

Koeryhmä: 
$$y_i = \underset{(4.68)}{0.64} + \underset{(0.064)}{0.53} x_i + \hat{\varepsilon}_i, \quad s_1^2 = 5.98$$

Kontrolliryhmä: 
$$y_i = \underset{(9.78)}{-25.80} + \underset{(0.13)}{0.75} x_i + \hat{\varepsilon}_i, \quad s_2^2 = 12.23.$$

Koeryhmä: 
$$y_i = \underset{(4.68)}{0.64} + \underset{(0.064)}{0.53} x_i + \hat{\varepsilon}_i, \quad s_1^2 = 5.98$$

Kontrolliryhmä: 
$$y_i = \underset{(9.78)}{-25.80} + \underset{(0.13)}{0.75} x_i + \hat{\varepsilon}_i, \quad s_2^2 = 12.23.$$

- **Kiinnostavia kysymyksiä:** Ovatko regressiosuorat yhdensuuntaisia eli voidaanko estimaattien 0.53 ja 0.75 välinen ero tulkita pelkästään satunnaisvaihtelusta johtuvaksi.
- Jos voidaan, on ruokavalion vaikutuksen mahdollinen ero riippumaton ruokinta-ajan pituudesta, jolloin regressiosuorien vakioiden ero mittaa sitä kaikilla selittävän muuttujan arvoilla.
- Jos regressiosuoria voidaan pitää yhdensuuntaisina, on seuraava kiinnostava kysymys siten voidaanko regressiosuorien vakioiden 0.64 ja -25.80 ero tulkita pelkästään satunnaisvaihtelusta johtuvaksi.

- Kiinnostavien kysymysten tutkiminen perustetaan lineaariseen malliin

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_{11} \\ Y_{12} \\ \vdots \\ Y_{22} \end{bmatrix} = \begin{bmatrix} 1 & 0 & x_1 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & x_{11} & 0 \\ 0 & 1 & 0 & x_{12} \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 1 & 0 & x_{22} \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \gamma_1 \\ \gamma_2 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_{11} \\ \varepsilon_{12} \\ \vdots \\ \varepsilon_{22} \end{bmatrix},$$

jossa  $\varepsilon_1, \dots, \varepsilon_{22} \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ .

- PNS  $\Rightarrow \hat{\alpha}_1 = 0.64, \hat{\gamma}_1 = 0.53, \hat{\alpha}_2 = -25.80, \hat{\gamma}_2 = 0.75$  ja  $s^2 = 9.10$  (vrt. aikaisempi).
- Ensimmäinen testattava hypoteesi on  $\gamma_1 = \gamma_2$  ja, jos se jää voimaan, testataan hypoteesia  $\alpha_1 = \alpha_2$ .
- Ennen testaamista on kuitenkin syytä tutkia ovatko mallista tehdyt oletukset realistiset.

# Mallin oletusten tarkistaminen

- Mallin oletusten tarkistamisessa residuaalit ovat keskeisiä. Tarkastellaan residuaalivektoria

$$\hat{\boldsymbol{\varepsilon}} = \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}, \quad \hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y},$$

jolla on esitys

$$\hat{\boldsymbol{\varepsilon}} = (\mathbf{I}_n - \mathbf{P}) \mathbf{y}, \quad \mathbf{P} = [p_{ij}] = \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \quad (\text{projektio}).$$

- Mallin ollessa oikein spesifioitu pätee vastaavalle sv:lle (HT 3.1)

$$E(\hat{\boldsymbol{\varepsilon}}) = \mathbf{0} \quad \text{ja} \quad \text{Cov}(\hat{\boldsymbol{\varepsilon}}) = \sigma^2 (\mathbf{I}_n - \mathbf{P}) \neq \sigma^2 \mathbf{I}_n = \text{Cov}(\boldsymbol{\varepsilon}).$$

- Residuaalit siis oikeinkin mallin kyseessä ollessa korreloituneita ja niiden varianssit vaihtelevat havaintoyksiköstä toiseen. Lisäksi, jos normaalisuusoletus  $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n)$  pätee, noudattaa residuaalivektori singulaarista normaalijakaumaa ( $r(\text{Cov}(\hat{\boldsymbol{\varepsilon}})) = n - p$ ).

# Mallin oletusten tarkistaminen

- Koska  $\text{Var}(\hat{\varepsilon}_i) = \sigma^2(1 - p_{ii})$ , on luontevaa tarkastella standardoituja residuaaleja


$$r_i = \hat{\varepsilon}_i / s\sqrt{1 - p_{ii}}, \quad s^2 = \frac{1}{n - p} \hat{\boldsymbol{\varepsilon}}' \hat{\boldsymbol{\varepsilon}},$$

joiden varianssi on likimain 1.

- Järjestetään standardoidut residuaalit  $r_{(1)} \leq r_{(2)} \leq \dots \leq r_{(n)}$ .
- Jos  $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n)$ , pätee ( $\Phi^{-1}$  on  $N(0, 1)$ -jakauman kf:n käänteisfunktio)

$$E(R_{(i)}) \approx \Phi^{-1}\left(\frac{i - 0.5}{n}\right) \approx r_{(i)}.$$

- Normaalisuusetusta voidaan siis tutkia tutkimalla ovatko pisteet  $\left(r_{(i)}, \Phi^{-1}\left(\frac{i - 0.5}{n}\right)\right)$ ,  $i = 1, \dots, n$ , likimain  $45^\circ$ :n suoralla.



**Kuva 5.2.** Mallin järjestetyt standardoidut residuaalit arvoja  $\Phi^{-1}((i - 0.5) / n)$  ( $i = 1, \dots, 22$ ) vastaan eli ns. normaalipaperipiirros (normal probability plot tai normal QQ plot).

Tämän perusteella normalisuusoletus näyttää kohtuulliselta.

- Muista oletuksista riippumattomuusoletus tuntuu perustellulta, koska kysymyksessä on satunnaisotanta, mutta vaihteleeko  $\text{Var}(\varepsilon_i)$  ryhmien mukaan?
- Koska virheiden  $\varepsilon_1, \dots, \varepsilon_{22}$  riippumattomuus voidaan olettaa, on  $S_1^2 \perp\!\!\!\perp S_2^2$  ja (Lause 2.1(ii))

$$\frac{S_1^2}{S_2^2} \stackrel{H_0}{\sim} \frac{1}{9}\chi_{1,9}^2 / \frac{1}{9}\chi_{2,9}^2 \sim F_{9,9} \quad \left( \chi_{i,9}^2 \sim \chi_9^2 \text{ ja } \chi_{1,9}^2 \perp\!\!\!\perp \chi_{2,9}^2 \right).$$

Testisuureen arvoksi saadaan

$$\frac{s_1^2}{s_2^2} = \frac{5.98}{12.23} = 0.49$$

ja P-arvoksi  $P(F_{9,9} \leq 0.49) = 0.15$ . Vakiovarianssioletus tuntuu siten kohtuulliselta.



- Rajoittamaton malli (malli (1)) on

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_{11} \\ Y_{12} \\ \vdots \\ Y_{22} \end{bmatrix} = \begin{bmatrix} 1 & 0 & x_1 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & x_{11} & 0 \\ 0 & 1 & 0 & x_{12} \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 1 & 0 & x_{22} \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \gamma_1 \\ \gamma_2 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_{11} \\ \varepsilon_{12} \\ \vdots \\ \varepsilon_{22} \end{bmatrix}, \quad \varepsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n),$$

josta estimaatit  $\hat{\alpha}_1 = 0.64$ ,  $\hat{\gamma}_1 = 0.53$ ,  $\hat{\alpha}_2 = -25.80$ , ja  $\hat{\gamma}_2 = 0.75$ .

- Tarkastellaan hypoteesia  $H_0 : \gamma_1 = \gamma_2 = \gamma$ .

- Rajoitettu malli on


$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_{11} \\ Y_{12} \\ \vdots \\ Y_{22} \end{bmatrix} = \begin{bmatrix} 1 & 0 & x_1 \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{11} \\ 0 & 1 & x_{12} \\ \vdots & \vdots & \vdots \\ 0 & 1 & x_{22} \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \gamma \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_{11} \\ \varepsilon_{12} \\ \vdots \\ \varepsilon_{22} \end{bmatrix}, \quad \varepsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n).$$

- Virhevarianssin estimaatiksi tulee  $s_H^2 = 9.76$  ja  $n - p_H = 22 - 3 = 19$ .
- Vapaasta mallista saatiin  $s^2 = 9.10$  ja  $n - p = 22 - 4 = 18$ .
- Testisuure saa arvon

$$F = \frac{(19 \times 9.76 - 18 \times 9.10) / 1}{9.10} = 2.37$$

ja vastaavaksi P-arvoksi tulee

$$P = P(F_{1,18} \geq 2.37) = 0.14 \Rightarrow H_0 : \gamma_1 = \gamma_2 \text{ jää voimaan.}$$



**Kuva 5.3.** Kuvan 5.1 aineistoon piirretyt mallin (2) estimointituloksiin perustuvat samansuuntaiset regressiosuorat.

Estimoitu malli

$$y_i = \underset{(4.98)}{-4.30} d_{i1} - \underset{(4.98)}{15.12} d_{i2} + \underset{(0.067)}{0.60} x_i + \hat{\varepsilon}_i, \quad s^2 = 9.76 \quad (2)$$

- Tarkastellaan nyt hypoteesia  $H_0 : \alpha_1 = \alpha_2 = \alpha$  mallissa (2)

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_{11} \\ Y_{12} \\ \vdots \\ Y_{22} \end{bmatrix} = \begin{bmatrix} 1 & 0 & x_1 \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{11} \\ 0 & 1 & x_{12} \\ \vdots & \vdots & \vdots \\ 0 & 1 & x_{22} \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \gamma \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_{11} \\ \varepsilon_{12} \\ \vdots \\ \varepsilon_{22} \end{bmatrix}, \quad \varepsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n).$$

- Rajoitettu malli on

$$Y_i = \alpha + \gamma x_i + \varepsilon_i, \quad i = 1, \dots, 22.$$

PNS-estimointi  $\Rightarrow$

$$y_i = \frac{-9.71}{(10.16)} + \frac{0.60}{(0.14)} x_i + \hat{\varepsilon}_i, \quad i = 1, \dots, 22, \quad s^2 = 41.46 \quad (3)$$

- Vapaassa mallissa (2)

$$s^2 = 9.76, \quad n - p = 22 - 3 = 19$$

- Rajoitetussa mallissa (3)

$$s^2 = 41.46, \quad n - p_H = 22 - 2 = 20$$

- Testisuure saa arvon

$$F = \frac{(20 \times 41.46 - 19 \times 9.76) / 1}{9.76} = 65.97$$

ja vastaavaksi P-arvoksi tulee

$$P = P(F_{1,19} \geq 65.97) \approx 0 \Rightarrow H_0 : \alpha_1 = \alpha_2 \text{ on syytä hylätä.}$$

- Malli (2)

$$Y_i = \alpha_1 d_{i1} + \alpha_2 d_{i2} + \gamma x_i + \varepsilon_i, \quad i = 1, \dots, 22.$$

- Ruokavalioiden eroa mittaa parametri

$$\alpha_1 - \alpha_2 = [1 \quad -1 \quad 0] \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \gamma \end{bmatrix} = \mathbf{a}'\boldsymbol{\beta}.$$

- $\hat{\alpha}_1 - \hat{\alpha}_2 = -4.30 + 15.12 = 10.82$ ,  $s\sqrt{\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}} = 1.77$ ,  
 $t_{19}(0.05/2) = 2.09$
- 95%:n luottamusväli erotukselle  $\alpha_1 - \alpha_2$  on

$$10.82 - 2.09 \cdot 1.77 < \alpha_1 - \alpha_2 < 10.82 + 2.09 \cdot 1.77$$

eli

$$7.12 < \alpha_1 - \alpha_2 < 14.52$$

- Uusi ruokavalio on (nopean painon nousun kannalta) systemaattisesti vanhaa parempi, sillä sen paremmuus ei riipu tarkasteltujen ruokinta-aikojen pituudesta.
- Kun ruokinta-ajan pituus on n. 50 - 90 päivää, voidaan uudella ruokavaliolla odottaa päästävän 95%:n varmuudella n. 7 - 14.5 naulaa suurempaan karitsan painon nousuun kuin vanhalla ruokavaliolla.

# Yksisuuntainen varianssianalyysi

Yksisuuntaisessa varianssianalyysissä tarkastellaan  $p$ :tä ryhmää ja niistä satunnaisotannalla poimittuja havaintoja. Mielenkiinnon kohteena on ryhmien odotusarvojen mahdolliset erot. Asetelma on kaaviona

	Havainnot	Keskiarvot
Ryhmä 1	$y_{11}, y_{12}, \dots, y_{1n_1}$	$\bar{y}_1$
Ryhmä 2	$y_{21}, y_{22}, \dots, y_{2n_2}$	$\bar{y}_2$
$\vdots$	$\vdots$	$\vdots$
Ryhmä $p$	$y_{p1}, y_{p2}, \dots, y_{pn_p}$	$\bar{y}_p$

jossa  $\bar{y}_j = (y_{j1} + \dots + y_{jn_j}) / n_j$  ( $j = 1, \dots, p$ ).



# Yksisuuntainen varianssianalyysi

- Tilastollista mallia varten oletetaan, että havaintoja vastaavat satunnaismuuttujat  $Y_{11}, \dots, Y_{1n_1}, Y_{21}, \dots, Y_{2n_2}, \dots, Y_{p1}, \dots, Y_{pn_p}$  ovat riippumattomia ja  $Y_{ji} \sim N(\mu_j, \sigma^2)$
- tai yhtäpitävästi, että

$$Y_{ji} = \mu_j + \varepsilon_{ji}, \quad i = 1, \dots, n_j, \quad j = 1, \dots, p,$$

jossa sm:t  $\varepsilon_{ji} \sim N(0, \sigma^2)$  ovat riippumattomia ja  $\mu_j \in \mathbb{R}$ .

- Käyttäen matriisimerkintöjä saadaan yhtälö

$$\begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_p \end{bmatrix} = \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{1}_{n_2} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{1}_{n_p} \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_p \end{bmatrix},$$

josta nähdään, että kysymyksessä on lineaarisen mallin erikoistapaus.

# Yksisuuntainen varianssianalyysi

- $Y_{ji} = \mu_j + \varepsilon_{ji}$ ,  $i = 1, \dots, n_j$ ,  $j = 1, \dots, p$ ,

jossa sm:t  $\varepsilon_{ji} \sim N(0, \sigma^2)$  ovat riippumattomia ja  $\mu_j \in \mathbb{R}$ .

- Mielenkiinnon kohteena on nollahypoteesi

$$H : \mu_1 = \dots = \mu_p \Leftrightarrow \mu_1 - \mu_p = \mu_2 - \mu_p = \dots = \mu_{p-1} - \mu_p = 0,$$

tai matriisein

$$\begin{bmatrix} 1 & 0 & 0 & \dots & \dots & -1 \\ 0 & 1 & 0 & \dots & \dots & -1 \\ \vdots & \vdots & \ddots & & & \vdots \\ \vdots & \vdots & & \ddots & & \vdots \\ 0 & 0 & 0 & & 1 & -1 \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \vdots \\ \mu_p \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ \vdots \\ 0 \end{bmatrix}.$$

- Nollahypoteesi on siis lineaarista muotoa  $\mathbf{A}\boldsymbol{\mu} = \mathbf{0}$ , jossa  $\mathbf{A}$  on  $(p-1) \times p$  matriisi ja  $r(\mathbf{A}) = p-1$ .

# Yksisuuntainen varianssianalyysi

- Kysymyksessä on lineaarinen malli

$$Y_{ji} = \mu_j + \varepsilon_{ji}, \quad i = 1, \dots, n_j, \quad j = 1, \dots, p, \quad (*)$$

jossa sm:t  $\varepsilon_{ji} \sim N(0, \sigma^2)$  ovat riippumattomia ja  $\mu_j \in \mathbb{R}$ . Testattava (lineaarinen) hypoteesi

$$H: \mu_1 = \dots = \mu_p := \mu_0.$$

- Testisuureen yleinen lauseke on  $(r(\mathbf{A}) = p - 1)$

$$F = \frac{(S(\hat{\boldsymbol{\mu}}_H) - S(\hat{\boldsymbol{\mu}})) / (p - 1)}{S(\hat{\boldsymbol{\mu}}) / (n - p)} \stackrel{H}{\sim} F_{p-1, n-p},$$

jossa parametrin  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_p)$  vapaa PNS-estimaatti  $\hat{\boldsymbol{\mu}}$  saadaan mallista (\*) ja sidottu PNS-estimaatti  $\hat{\boldsymbol{\mu}}_H$  mallista

$$Y_{ji} = \mu_0 + \varepsilon_{ji}, \quad i = 1, \dots, n_j, \quad j = 1, \dots, p.$$

- Sidottu PNS-estimaatti  $\hat{\boldsymbol{\mu}}_H$  minimoi jäännöselineliösumman

$$S(\boldsymbol{\mu}_0) = \sum_{j=1}^p \sum_{i=1}^{n_j} (y_{ji} - \mu_0)^2.$$

Siten,  $\hat{\boldsymbol{\mu}}_H = (\bar{y}, \dots, \bar{y})$ , jossa

$$\hat{\mu}_0 = \bar{y} = \frac{1}{n} \sum_{j=1}^p \sum_{i=1}^{n_j} y_{ji} = \frac{1}{n} \sum_{j=1}^p n_j \bar{y}_j \quad (n = n_1 + \dots + n_p),$$

ja

$$S(\hat{\boldsymbol{\mu}}_H) = \sum_{j=1}^p \sum_{i=1}^{n_j} (y_{ji} - \bar{y})^2.$$

- Vapaa PNS-estimaatti  $\hat{\boldsymbol{\mu}}$  minimoi jäännöselineliösumman

$$S(\boldsymbol{\mu}) = \sum_{j=1}^p \sum_{i=1}^{n_j} (y_{ji} - \mu_j)^2.$$

- Tämä johtaa estimaatteihin  $\hat{\mu}_j = \bar{y}_j = (y_{j1} + \dots + y_{jn_j}) / n_j$ , joten  $\hat{\boldsymbol{\mu}} = (\bar{y}_1, \dots, \bar{y}_p)$  ja

$$S(\hat{\boldsymbol{\mu}}) = \sum_{j=1}^p \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2$$

- Testisuureksi saadaan

$$F = \frac{S(\hat{\boldsymbol{\mu}}_H) - S(\hat{\boldsymbol{\mu}}) / (p - 1)}{S(\hat{\boldsymbol{\mu}}) / (n - p)}$$
$$= \frac{\left( \sum_{j=1}^p \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y})^2 - \sum_{j=1}^p \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2 \right) / (p - 1)}{\sum_{j=1}^p \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2 / (n - p)}$$
$$\stackrel{H}{\sim} F_{p-1, n-p},$$

- Tämä riittää, mutta testisuure on perinteisesti esitetty hieman toisessa muodossa.

- Laskemalla nähdään, että  $F$ -testisuureen osoittaja voidaan kirjoittaa

$$S(\hat{\boldsymbol{\mu}}_H) - S(\hat{\boldsymbol{\mu}}) = \sum_{j=1}^p \sum_{i=1}^{n_j} (\bar{y}_j - \bar{y})^2 = \sum_{j=1}^p n_j (\bar{y}_j - \bar{y})^2,$$

joten  $F$ -testisuureksi saadaan

$$F = \frac{\sum_{j=1}^p n_j (\bar{Y}_j - \bar{Y})^2 / (p-1)}{\sum_{j=1}^p \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2 / (n-p)} \stackrel{H}{\sim} F_{p-1, n-p}.$$

- Usein sanotaan, että testisuure on ryhmien välisen varianssin ja ryhmien sisäisen varianssin suhde, mistä nimitys varianssianalyysi tulee.
- Huomaa, että testisuureen nimittäjässä on  $S(\hat{\boldsymbol{\mu}}) / (n-p) = S^2$ .

# Yksisuuntainen varianssianalyysi

- Jos nollahypoteesi hylätään, on kiinnostavaa tutkia hypoteeseja  $\mu_{j_1} - \mu_{j_2} = 0$  tai yleisemmin ns. *kontrasteja*  $\mathbf{a}'\boldsymbol{\mu} = 0$ , jossa  $\mathbf{a}' = [a_1 \cdots a_p]$  toteuttaa  $a_1 + \cdots + a_p = 0$ .

- Koska  $\mathbf{X}'\mathbf{X} = \text{diag}[n_1 \cdots n_p]$ , pätee (Lauseen 2.1(i))

$$\hat{\boldsymbol{\mu}} = [\bar{Y}_1 \cdots \bar{Y}_p]' \sim N\left(\boldsymbol{\mu}, \sigma^2 \text{diag}\left[\frac{1}{n_1} \cdots \frac{1}{n_p}\right]\right).$$

- Nollahypoteesin  $\mathbf{a}'\boldsymbol{\mu} = 0$  voimassa ollessa pätee siten (Liite A.2.4)

$$\mathbf{a}'\hat{\boldsymbol{\mu}} \sim N\left(0, \sigma^2 \sum_{j=1}^p a_j^2 / n_j\right).$$

- Tämä johtaa  $F$ -testisuureeseen

$$F = \frac{\left(\sum_{j=1}^p a_j \bar{Y}_j\right)^2}{S^2 \sum_{j=1}^p a_j^2 / n_j} \stackrel{H}{\sim} F_{1, n-p}, \quad S^2 = \frac{1}{n-p} \sum_{j=1}^p \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2.$$



# Yksisuuntainen varianssianalyysi

- $F$ -testisuureen

$$F = \frac{\left(\sum_{j=1}^p a_j \bar{Y}_j\right)^2}{S^2 \sum_{j=1}^p a_j^2 / n_j} \stackrel{H}{\sim} F_{1, n-p}, \quad S^2 = \frac{1}{n-p} \sum_{j=1}^p \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2$$

vaihtoehtona voidaan käyttää testisuuretta (ks. jakso 4.1)

$$T = \frac{\sum_{j=1}^p a_j \bar{Y}_j}{S \sqrt{\sum_{j=1}^p a_j^2 / n_j}} \stackrel{H}{\sim} t_{n-p}$$

- Kontrastin  $\mathbf{a}'\boldsymbol{\mu}$  luottamusväliksi luottamustasolla  $1 - \alpha$  saadaan

$$\sum_{j=1}^p a_j \bar{y}_j \pm t_{n-p}(\alpha/2) s \sqrt{\sum_{j=1}^p a_j^2 / n_j}.$$

- Useita luottamusvälejä muodostettaessa on kuitenkin syytä muistaa jaksossa 4.1 mainitut hankaluudet.