

# F-testi yleiselle lineaariselle hypoteesille

- Oletetaan lin. malli  $\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}_n)$  ( $r(\mathbf{X}) = p$ ), ja tarkastellaan nollahypoteesia

$$H: \mathbf{A}\boldsymbol{\beta} = \mathbf{c}, \quad \mathbf{A} \ (q \times p) \quad \text{ja} \quad \mathbf{c} \ (q \times 1) \quad \text{tunnettuja,} \quad r(\mathbf{A}) = q.$$

- Testi on luontevaa perustaa erotukseen  $\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}$ , jossa  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$  on  $\boldsymbol{\beta}$ :n (vapaa) PNS-estimaattori tai yhtäpitävästi (vapaa) SU-estimaattori.
- Koska  $\hat{\boldsymbol{\beta}}$  estimoi  $\boldsymbol{\beta}$ :aa tehokkaasti olipa  $H$  tosi vai ei, pätee aina  $\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c} \approx \mathbf{A}\boldsymbol{\beta} - \mathbf{c}$ . Erotus  $\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}$  saa siten tyypillisesti "pieniä" arvoja, kun  $H$  on tosi ja "suuria" arvoja, kun  $H$  ei ole tosi.
- Lausetta 2.1 käyttäen voidaan johtaa testisuure, jonka avulla erotuksen  $\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}$  suuruutta voidaan arvioida.
- Saatava testi perustuu tilastollisen päättelyn kurssilla esitetyn Waldin testin periaatteeseen.

# F-testi yleiselle lineaariselle hypoteesille

- Oletetaan lin. malli  $\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$  ( $r(\mathbf{X}) = p$ ), ja tarkastellaan nollahypoteesia

$$H: \mathbf{A}\boldsymbol{\beta} = \mathbf{c}, \quad \mathbf{A} \ (q \times p) \quad \text{ja} \quad \mathbf{c} \ (q \times 1) \quad \text{tunnettuja,} \quad r(\mathbf{A}) = q.$$

- Ns. F-testi hypoteesille  $H$  perustuu  $\boldsymbol{\beta}$ :n (vapaaseen) PNS-estimaattoriin  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$  ja  $\sigma^2$ :n harhattomaan estimaattoriin  $S^2 = (n-p)^{-1}(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})$ .
- Testisuurena on ns.  $F$ -testisuure

$$F = (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c})'(\mathbf{A}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}')^{-1}(\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c})/qS^2 \stackrel{H}{\sim} F_{q,n-p}$$

- Suuret  $F$ :n arvot ovat kriittisiä nollahypoteesin kannalta. P-arvot:

$$P = P_H(F(\mathbf{Y}) \geq F(\mathbf{y})) = P(F_{q,n-p} \geq F(\mathbf{y})),$$

jossa  $F_{q,n-p}$  on  $F_{q,n-p}$ -jakaumaa noudattava satunnaismuuttuja.

# F-testi yleiselle lineaariselle hypoteesille

- $F$ -testisuure

$$F = (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c})'(\mathbf{A}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}')^{-1}(\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c})/qS^2 \stackrel{H}{\sim} F_{q,n-p},$$

jossa  $S^2 = (n-p)^{-1}(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = S(\hat{\boldsymbol{\beta}})/(n-p)$  ja  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$  voidaan kirjoittaa myös

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

- Siis,  $F$ -testi asettaa nollahypoteesin epäilyksen alaiseksi, jos rajoitettu residuaalineliosumma  $S(\hat{\boldsymbol{\beta}}_H) = (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_H)'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_H)$  on "kohtuuttoman paljon" suurempi kuin vapaa residuaalineliosumma  $S(\hat{\boldsymbol{\beta}}) = (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})$ .

- Suoraviivaisella laskulla nähdään, että uskottavuusosamäärän testisuure on

$$\begin{aligned}r(\mathbf{y}) &= 2 \left[ l(\hat{\boldsymbol{\beta}}, \hat{\sigma}^2; \mathbf{y}) - l(\hat{\boldsymbol{\beta}}_H, \hat{\sigma}_H^2; \mathbf{y}) \right] \\ &= 2 \left[ \frac{n}{2} \log \hat{\sigma}_H^2 + \frac{n}{2} - \frac{n}{2} \log \hat{\sigma}^2 - \frac{n}{2} \right] \\ &= n \log \left( \frac{q}{n-p} F + 1 \right).\end{aligned}$$

- Koska  $r(\mathbf{y})$  on monotonisesti kasvava funktio  $F$ -testisuureesta, määrittelevät molemmat testisuureet saman testin eli samat  $P$ -arvot.
- Voidaan osoittaa, että myös Raon pistemäärätestisuure ja  $F$ -testisuure määrittelevät saman testin.

# F-testin erikoistapauksia

- Sovelletaan  $F$ -testiä usean selittäjän regressiomalliin

$$Y_i = \beta_1 + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i, \quad i = 1, \dots, n,$$

johtamalla ns. *yleistesti*, joka koskee nollahypoteesia

$$H: \beta_2 = \cdots = \beta_p = 0 \quad \text{eli} \quad [\mathbf{0} \quad \mathbf{I}_{p-1}] \boldsymbol{\beta} = \mathbf{0}.$$

Nollahypoteesin voimassa ollessa mallilla ei ole mitään virkaa.

- Tässä tapauksessa kannattaa käyttää testiruureen residuaalineliosummamuotoa ( $q = p - 1$ )

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

- Testisuure voidaan kirjoittaa (välivaiheiden jälkeen)

$$F = \frac{(\hat{\boldsymbol{\beta}}' \mathbf{X}' \mathbf{Y} - n \bar{Y}^2) / (p - 1)}{(\mathbf{Y}' \mathbf{Y} - \hat{\boldsymbol{\beta}}' \mathbf{X}' \mathbf{Y}) / (n - p)} \stackrel{H}{\sim} F_{p-1, n-p}.$$

# F-testin erikoistapauksia

- Sovelletaan  $F$ -testiä malliin ( $x_{i1} = 1 \forall i$  ei välttämätöntä)

$$Y_i = \beta_1 x_{i1} + \cdots + \beta_p x_{ip} + \varepsilon_i, \quad i = 1, \dots, n,$$

johtamalla ns. *yksittäistä selittäjää koskeva testi*, jossa nollahypot. on

$$H_j : \beta_j = 0, \quad 1 \leq j \leq p \quad \text{eli} \quad [0 \cdots 0 \ 1 \ 0 \cdots 0] \boldsymbol{\beta} = 0.$$

Nollahypoteesi merkitsee, että muiden selittäjien ollessa mallissa tutkitaan onko selittäjä  $x_j$  tarpeen.

- Tässä tapauksessa kannattaa käyttää testiruureen "alkuperäistä" muotoa ( $q = 1$ )

$$F = (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c})' (\mathbf{A} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{A}')^{-1} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}) / S^2 \stackrel{H}{\sim} F_{1, n-p}.$$

- Testisuureeksi saadaan (välivaiheiden jälkeen)

$$F = \hat{\beta}_j^2 / S^2 m^{jj} \stackrel{H}{\sim} F_{1, n-p}, \quad (\mathbf{X}'\mathbf{X})^{-1} = \mathbf{M}^{-1} = [m^{ab}], \quad a, b = 1, \dots, p.$$

# F-testin erikoistapauksia

- Vaihtoehto testisuurelle

$$F = \hat{\beta}_j^2 / S^2 m^{jj} \stackrel{H}{\sim} F_{1, n-p}, \quad (\mathbf{X}'\mathbf{X})^{-1} = \mathbf{M}^{-1} = [m^{ab}], \quad a, b = 1, \dots, p.$$

- Jos  $Z \sim N(0, 1)$  ja  $Z \perp\!\!\!\perp \chi_k^2$ , niin tunnetusti  $T_k = Z / \sqrt{\frac{1}{k} \chi_k^2} \sim t_k$  ( $t$ -jakauma vapausastein  $k$ ) ja  $T_k^2 \sim F_{1, k}$ . Nollahypoteesia voidaan siten testata myös testisuurella

$$T = t(\mathbf{Y}) = \hat{\beta}_j / S \sqrt{m^{jj}} \stackrel{H}{\sim} t_{n-p}.$$

- Tämän testin P-arvot:

$$P = P_{H_j} (|t(\mathbf{Y})| \geq |t(\mathbf{y})|) = P (|T_{n-p}| \geq |t(\mathbf{y})|), \quad T_{n-p} \sim t_{n-p}$$

- Tässä vaihtoehto on kaksisuuntainen eli  $\beta_j \neq 0$ . Yksisuuntaisen vaihtoehdon  $\beta_j > 0$  [tai  $\beta_j < 0$ ] tapauksessa P-arvot lasketaan kaavalla  $P (T_{n-p} \geq t(\mathbf{y}))$  [tai  $P (T_{n-p} \leq t(\mathbf{y}))$ ].

# F-testin erikoistapauksia

Käytännössä käytetään yleensä  $t$ -testisuuretta ja tuloksista voidaan laatia seuraavanlainen taulukko ( $\hat{\beta}_j$ :n keskivirhe =  $\hat{\beta}_j$ :n estimoitu hajonta)

Parametri	Estimaatti	Keskivirhe	$t$ -suhde
$\beta_1$	$\hat{\beta}_1$	$s\sqrt{m^{11}}$	$\hat{\beta}_1 / s\sqrt{m^{11}}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$\beta_p$	$\hat{\beta}_p$	$s\sqrt{m^{pp}}$	$\hat{\beta}_p / s\sqrt{m^{pp}}$

tai yhtälö ( $s.e.(\hat{\beta}_j)$  on  $\hat{\beta}_j$ :n keskivirhe)

$$y_i = \underbrace{\hat{\beta}_1}_{(s.e.(\hat{\beta}_1))} x_{i1} + \cdots + \underbrace{\hat{\beta}_p}_{(s.e.(\hat{\beta}_p))} x_{ip} + \hat{\varepsilon}_i, \quad s^2 = \dots,$$



# F-testin erikoistapauksia

## Huomautuksia

- Eri hypoteeseihin  $H_j : \beta_j = 0$  liittyvät  $t$ -testit eivät ole riippumattomia, joten "yhdistetyn" testin  $P$ -arvon laskeminen on hankalaa.
- Yksittäisiä hypoteeseja  $H_j$  ei ilmeisestikään kannata testata, ellei yleishypoteesia  $H : \beta_2 = \dots = \beta_p = 0$  (jossa ei yo hankaluutta) ole ohyllätty.
- Mahdollista, että yleishypoteesi hylätään ja kaikki yksittäiset hypoteesit jäävät voimaan.
- Jos  $H_j$ :ta ei hylätä, on  $j$ . selittäjä tarpeeton. Selittäjien poistaminen ei ole kuitenkaan yksiselitteistä. Esimerkiksi lopputulos voi riippua yksittäisten hypoteesien testausjärjestyksestä

# Esimerkki

Äitien ja tyttärien pituudet (tuumissa):  $n = 30$ , punainen suora perustuu PNS-estimointiin  $y = 17.29 + 0.75x + \hat{\varepsilon}_t$ ,  $s^2 = 6.43$ ,  $R^2 = 0.49$ .  
(9.07) (0.14)

Sininen katkoviiva  $y = 1.53 + x$ .  $H_0 : \beta_2 = 1$ ,  $H_1 : \beta_2 \neq 0$ .

$t(\mathbf{y}) = (0.75 - 1) / 0.14 = -1.79$ ,  $P \approx 0.085$ .

