

## Peatükk 3

# Parameeterfunktsiooni $\boldsymbol{\lambda}^T \boldsymbol{\beta}$ hinnangust

Vaatame hinnatavat parameeterfunktsiooni  $\boldsymbol{\lambda}^T \boldsymbol{\beta} = \mathbf{v}^T \mathbf{X} \boldsymbol{\beta}$ . Nagu juba teame, on hinnang  $\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}$  nihketa,  $E(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}) = \boldsymbol{\lambda}^T \boldsymbol{\beta}$ . Ka hinnangu dispersioon on lihtsalt leitav:

$$\begin{aligned} D(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}) &= D(\mathbf{v}^T \mathbf{P}_X \mathbf{y}) \\ &= \mathbf{v}^T \mathbf{P}_X D(\mathbf{y}) \mathbf{P}_X \mathbf{v} \\ &= \sigma^2 \mathbf{v}^T \mathbf{P}_X \mathbf{v} \\ &= \sigma^2 \boldsymbol{\lambda}^T (\mathbf{X}^T \mathbf{X})^{-1} \boldsymbol{\lambda}. \end{aligned}$$

Paneme tähele, et juhul kui  $\boldsymbol{\beta}$  on ise hinnatav, siis on ka hinnangu  $\hat{\boldsymbol{\beta}}$  dispersioon üheselt määratud:

$$D(\hat{\boldsymbol{\beta}}) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}$$

ja sellisel juhul võime kirjutada:

$$D(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}) = \boldsymbol{\lambda}^T D(\hat{\boldsymbol{\beta}}) \boldsymbol{\lambda}.$$

Juhul, kui vaatlusvektor on normaaljaotusega,  $\mathbf{y} \sim N(\mathbf{X} \boldsymbol{\beta}; \sigma^2 \mathbf{I})$ , siis on ka hinnangu  $\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}$  jaotuseks normaaljaotus (sest lineaarteisendus ei hävita normaaljaotust):

$$\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\lambda}^T \boldsymbol{\beta}; \boldsymbol{\lambda}^T (\mathbf{X}^T \mathbf{X})^{-1} \boldsymbol{\lambda} \sigma^2).$$

Juhul kui  $\boldsymbol{\beta}$  ise on hinnatav, siis

$$\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}; (\mathbf{X}^T \mathbf{X})^{-1} \sigma^2).$$

Et saada reaalselt arvutatavat  $\hat{\beta}$  dispersiooni hinnangut, peaksime leidma viisi hindamaks parameetrit  $\sigma^2$ . Soovitav oleks nihketa hinnang — poleks ju ilus oma töö täpsuse iseloomustamisel tehtavat viga pisemaks muuta. Alustuseks uurime, milline tuleb vigade ruutude summa  $\mathbf{y}^T(\mathbf{I} - \mathbf{P}_X)\mathbf{y}$  keskväärtaus. Esmalt aga tõestame ühe abitulemuse:

**Lemma 3.1** *Olgu  $\mathbf{A}$  suvaline  $n \times n$  maatriks,  $E\mathbf{y} = \boldsymbol{\mu}$  ja  $D\mathbf{y} = \mathbf{V}$ . Siis*

$$E(\mathbf{y}^T \mathbf{A} \mathbf{y}) = \text{tr}(\mathbf{A} \mathbf{V}) + \boldsymbol{\mu}^T \mathbf{A} \boldsymbol{\mu}.$$

Tõestus.

$$\begin{aligned} E(\mathbf{y}^T \mathbf{A} \mathbf{y}) &= E(\text{tr}(\mathbf{A} \mathbf{y} \mathbf{y}^T)) \\ &= \text{tr}(\mathbf{A} E(\mathbf{y} \mathbf{y}^T)) \\ &= \text{tr}(\mathbf{A}(\mathbf{V} + \boldsymbol{\mu} \boldsymbol{\mu}^T)) \\ &= \text{tr}(\mathbf{A} \mathbf{V}) + \boldsymbol{\mu}^T \mathbf{A} \boldsymbol{\mu}. \end{aligned}$$

Varustatud ülaltoodud abitulemusega, on edasine muidugi lihtne:

$$\begin{aligned} E[\mathbf{y}^T(\mathbf{I} - \mathbf{P}_X)\mathbf{y}] &= \text{tr}((\mathbf{I} - \mathbf{P}_X)\sigma^2) + \boldsymbol{\beta}^T \mathbf{X}^T (\mathbf{I} - \mathbf{P}_X) \mathbf{X} \boldsymbol{\beta} \\ &= \text{tr}((\mathbf{I} - \mathbf{P}_X)\sigma^2) \\ &= \sigma^2 \text{tr}(\mathbf{I} - \mathbf{P}_X) \\ &= \sigma^2(n - \text{rank}(\mathbf{X})). \end{aligned}$$

Seega võiksime kasutada  $\sigma^2$  nihketa hinnanguna suurust:

$$\hat{\sigma}^2 = \mathbf{y}^T(\mathbf{I} - \mathbf{P}_X)\mathbf{y} / \text{rank}(\mathbf{I} - \mathbf{P}_X)$$

antud suurust tuntakse ka nime keskmine ruutviga ehk MSE (Mean Square Error) all.

**Definitsioon 3.1** *Kui  $p \times 1$  vektor  $\mathbf{y}$  on normaaljaotusega,  $\mathbf{y} \sim N(\boldsymbol{\mu}; \mathbf{I})$ , siis  $\mathbf{y}^T \mathbf{y}$  on mittetsentraalse hii-ruut ( $\chi^2$ ) jaotusega juhuslik suurus vabadusastmete arvuga  $p$  ja mittetsentraalsuse parameetriga  $n\boldsymbol{\mu}^T \boldsymbol{\mu}$ ,*

$$\mathbf{y}^T \mathbf{y} \sim \chi_{df=p; ncp=\boldsymbol{\mu}^T \boldsymbol{\mu}}^2$$

**Teoreem 3.1** Olgu  $\mathbf{y} \sim N(\boldsymbol{\mu}; \mathbf{I})$ , ja olgu maatriks  $\mathbf{A}$  ortogonaalne projektor (sümmeetriline ja idempotentne). Siis

$$\mathbf{y}^T \mathbf{A} \mathbf{y} \sim \chi_{df=\text{rank}(\mathbf{A}); ncp=\boldsymbol{\mu}^T \mathbf{A} \boldsymbol{\mu}}^2$$

Tõestus.

Maatriksi  $\mathbf{A}$  saame esitada kahe ortogonaalse maatriksi korrutisena (maatriksi spektraallahutus, idempotentse maatriksi omaväärtused saavad olla vaid kas 0 või 1):  $\mathbf{A} = \mathbf{O} \mathbf{O}^T$ , kusjuures  $\mathbf{O}^T \mathbf{O} = \mathbf{I}_{\text{rank}(\mathbf{A})}$ . Seega

$$\mathbf{O}^T \mathbf{y} \sim N(\mathbf{O}^T \boldsymbol{\mu}; \mathbf{O}^T \mathbf{O} (= \mathbf{I}_{\text{rank}(\mathbf{A})}))$$

ja järelikult (definiitsiooni kohaselt)

$$\begin{aligned} (\mathbf{O}^T \mathbf{y})^T (\mathbf{O}^T \mathbf{y}) &\sim \chi_{\text{rank}(\mathbf{A}), \boldsymbol{\mu}^T \mathbf{O} \mathbf{O}^T \boldsymbol{\mu}}^2 \\ \mathbf{y}^T \mathbf{A} \mathbf{y} &\sim \chi_{\text{rank}(\mathbf{A}), \boldsymbol{\mu}^T \mathbf{A} \boldsymbol{\mu}}^2 \end{aligned}$$

□

Märkus 1: analoogne tulemus on tõestatav ka veidi üldisemal kujul:

**Teoreem 3.2** Kui  $\mathbf{y} \sim N(\boldsymbol{\mu}; \mathbf{V})$ , siis  $\mathbf{y}^T \mathbf{A} \mathbf{y} \sim \chi_{r, ncp}^2$ ,  $r := \text{rank}(\mathbf{A})$ ,  $ncp := \boldsymbol{\mu}^T \mathbf{A} \boldsymbol{\mu}$  siis ja ainult siis kui maatriks  $\mathbf{A} \mathbf{V}$  on idempotentne.

Märkus 2: Kuna maatriks  $\mathbf{I} - \mathbf{P}_{\mathbf{X}}$  on ortogonaalne projektor (sümmeetriline ja idempotentne), siis prognoosijääkide ruutude summa jagatud  $\sigma^2$ -ga on hii-ruut jaotusega:

$$\begin{aligned} \mathbf{y}^T (\mathbf{I} - \mathbf{P}_{\mathbf{X}}) \mathbf{y} / \sigma^2 &\sim \chi_{\text{rank}(\mathbf{I} - \mathbf{P}_{\mathbf{X}})}^2 \\ &\sim \chi_{n - \text{rank}(\mathbf{X})}^2 \end{aligned} \quad (3.1)$$

Saadud tulemust saab kasutada näiteks  $\sigma^2$ -le usaldusintervalli leidmiseks. Kui tähistame vabadusastmete arvuga  $df$  hii-ruut jaotuse  $\alpha$  kvantiili sümbooliga  $\chi_{\alpha; df}$  siis võime tulemust 3.1 kasutades kirjutada

$$\begin{aligned} P(\chi_{\alpha/2; n-p} \leq \mathbf{y}^T (\mathbf{I} - \mathbf{P}_{\mathbf{X}}) \mathbf{y} / \sigma^2 \leq \chi_{1-\alpha/2; n-p}) &= 1 - \alpha \\ P\left(1/\chi_{\alpha/2; n-p} \geq \frac{\sigma^2}{\mathbf{y}^T (\mathbf{I} - \mathbf{P}_{\mathbf{X}}) \mathbf{y}} \geq 1/\chi_{1-\alpha/2; n-p}\right) &= 1 - \alpha \\ P(\mathbf{y}^T (\mathbf{I} - \mathbf{P}_{\mathbf{X}}) \mathbf{y} / \chi_{\alpha/2; n-p} \geq \sigma^2 \geq \mathbf{y}^T (\mathbf{I} - \mathbf{P}_{\mathbf{X}}) \mathbf{y} / \chi_{1-\alpha/2; n-p}) &= 1 - \alpha. \end{aligned}$$

Ehk siis  $1 - \alpha$  usaldusintervalli jääkide dispersioonile avaldub kujul:

$$\mathbf{y}^T(\mathbf{I} - \mathbf{P}_X)\mathbf{y} / \chi_{1-\alpha/2; n-p} \cdots \mathbf{y}^T(\mathbf{I} - \mathbf{P}_X)\mathbf{y} / \chi_{\alpha/2; n-p}.$$

Üritame nüüd kokku panna teadmised hinnatava parameeterfunktsiooni hinnangu jaotuse ja prognoosijääkide ruutude summa kohta. Esmalt tähele pane, et juhuslikud suurused  $\mathbf{P}_X \mathbf{y}$  ja  $(\mathbf{I} - \mathbf{P}_X)\mathbf{y}$  on sõltumatud (juhul kui  $\mathbf{y}$  on normaaljaotusega piisab, kui näitame, et kovariatsioon on 0):

$$\begin{aligned} \text{cov}(\mathbf{P}_X \mathbf{y}, (\mathbf{I} - \mathbf{P}_X)\mathbf{y}) &= \mathbf{P}_X \text{cov}(\mathbf{y}, \mathbf{y})(\mathbf{I} - \mathbf{P}_X)^T \\ &= \sigma^2 \mathbf{P}_X (\mathbf{I} - \mathbf{P}_X)^T \\ &= 0 \end{aligned}$$

Aga kui  $Y_1$  ja  $Y_2$  on sõltumatud juhuslikud suurused  $Y_1 \perp Y_2$ , siis on sõltumatud ka nende juhuslike suuruste mistahes funktsioonid,  $f_1(Y_1) \perp f_2(Y_2)$ .

Hinnatava parameeterfunktsiooni  $\lambda^T \beta$  hinnangu jaotus oli normaaljaotus:

$$\begin{aligned} \lambda^T \hat{\beta} &\sim N(\lambda^T \beta, \lambda^T (\mathbf{X}^T \mathbf{X})^{-1} \lambda \sigma^2) \\ \frac{\lambda^T \hat{\beta} - \lambda^T \beta}{\sqrt{\lambda^T (\mathbf{X}^T \mathbf{X})^{-1} \lambda \sigma^2}} &\sim N(0; 1) \end{aligned}$$

ja jääkide ruutude summa (jagatud vaatluste dispersiooniga) jaotus oli hii-ruut jaotus. Kui  $Y_1 \sim N(0; 1)$  ja  $Y_2 \sim \chi_k^2$ , ja kui  $Y_1 \perp Y_2$ , siis  $t = Y_1 / \sqrt{Y_2/k} \sim t_k$ . Seega

$$\begin{aligned} t &:= \frac{\lambda^T \hat{\beta} - \lambda^T \beta}{\sqrt{\lambda^T (\mathbf{X}^T \mathbf{X})^{-1} \lambda \sigma^2}} / \sqrt{\frac{\mathbf{y}^T (\mathbf{I} - \mathbf{P}_X)\mathbf{y}}{(n-p)\sigma^2}} \\ &= \frac{\lambda^T \hat{\beta} - \lambda^T \beta}{\sqrt{MSE \cdot \lambda^T (\mathbf{X}^T \mathbf{X})^{-1} \lambda}} \end{aligned}$$

on  $t$ -jaotusega juhuslik suurus,  $t \sim t_{n-p}$ , kus  $p := \text{rank}(\mathbf{X})$ .

Milleks saame seda teadmist kasutada? Muidugi hüpoteeside testimiseks:

$$t := \frac{\lambda^T \hat{\beta} - \lambda^T \beta_0}{\sqrt{MSE \cdot \lambda^T (\mathbf{X}^T \mathbf{X})^{-1} \lambda}} \stackrel{H_0}{\sim} t_{n-p}.$$

Märkus:

Kuna  $D(\lambda^T \hat{\beta}) = \lambda^T (\mathbf{X}^T \mathbf{X})^{-1} \lambda \sigma^2$  ja  $E(MSE) = \sigma^2$  siis nihketa hinnanguks

hinnangu  $\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}$  dispersioonile on

$$\widehat{D(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}})} = MSE \cdot \boldsymbol{\lambda}^T (\mathbf{X}^T \mathbf{X})^{-1} \boldsymbol{\lambda}$$

Seega võime  $t$ -statistiku ülestähendamisel kasutada ka ehk tuttavamana näivat kiriapilti:

$$t := \frac{\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}} - \boldsymbol{\lambda}^T \boldsymbol{\beta}_0}{\sqrt{\widehat{D(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}})}}.$$

Samuti saame välja kirjutada  $(1 - \alpha)$ -usaldusintervalli  $\boldsymbol{\lambda}^T \boldsymbol{\beta}$ -le:

$$P \left( t_{\alpha/2} \leq \frac{\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}} - \boldsymbol{\lambda}^T \boldsymbol{\beta}}{\sqrt{\widehat{D(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}})}}} \leq t_{1-\alpha/2} \right) = 1 - \alpha$$

$$P \left( \boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}} + t_{\alpha/2} \sqrt{\widehat{D(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}})}} \leq \boldsymbol{\lambda}^T \boldsymbol{\beta} \leq \boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}} + t_{1-\alpha/2} \sqrt{\widehat{D(\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}})}} \right) = 1 - \alpha,$$

kus  $t_{1-\alpha/2}$  tähistab vabadusastmete arvuga  $n - p$   $t$ -jaotuse  $1 - \alpha/2$ -kvantiili.

## Ülesanded

1. Vaata lihtsat dispersioonanalüüsi mudelit

$$y_{ij} = \mu + \alpha_i + \varepsilon_{ij}, \quad i = 1, 2; j = 1, \dots, n_i.$$

Defineerime  $\boldsymbol{\beta}^T = (\mu, \alpha_1, \alpha_2)$ . Antud mudeli parameetreid hinnati muiste kahe erineva teadlase poolt (kahes sõltumatus uuringus). Esimeses uuringus  $n_1 = 2; n_2 = 5$ ; teises uuringus  $n_1 = 10; n_2 = 30$ . Esimesest uuringust on säilinud suuruse  $\boldsymbol{\lambda}^T \boldsymbol{\beta}$  hinnang  $\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}$ , kus  $\boldsymbol{\lambda}^T = (0; 1; -1)$ . Paraku pole aga esimese uuringu autor kirja pannud jääkide dispersiooni hinnangut. Teisest uuringust on säilinud jääkide dispersiooni hinnang  $MSE_2$ , kuid pole paraku säilinud parameetervektori  $\boldsymbol{\beta}$  hinnangut. Tahame testida hüpoteesi  $H_0 : \boldsymbol{\lambda}^T \boldsymbol{\beta} = 0$  ja kasutame selleks teststatistikut

$$t := \frac{\boldsymbol{\lambda}^T \hat{\boldsymbol{\beta}}}{\sqrt{MSE_2 \cdot \boldsymbol{\lambda}^T (\mathbf{X}^T \mathbf{X})^{-1} \boldsymbol{\lambda}}}.$$

- Kas  $t$ -statistiku valemis peaks mudelimaatriks  $\mathbf{X}$  olema 1. uuringu mudelimaatriks või 2. uuringu mudelimaatriks?
- Näita, et ülaltoodud  $t$ -statistik on nullhüpoteesi kehtides  $t$ -jaotusega. Leia antud  $t$ -statistiku vabadusastmete arv.