

Peatükk 1

Sissejuhatus

1.1 Lineaarse mudeli definitsioon

Lineaarne mudel on mudeli parameetrite lineaarne funktsioon. Tüüpiline lineaarne mudel näeb välja järgmine:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (1.1)$$

kus \mathbf{y} on $n \times 1$ vektor, mis sisaldab n vaadeldavat (või mõõdetavat) väärtust, \mathbf{X} on $n \times p$ maatriks, mille elementideks olevaid konstante me teame. Maatriksit \mathbf{X} tuntakse sageli ka mudeli- või disainimaatriksi nime all; $\boldsymbol{\beta}$ on $p \times 1$ hindamist vajavate (tundmatute) parameetrite vektor; $\boldsymbol{\varepsilon}$ on $n \times 1$ juhuslike vigade vektor (sageli räägitakse temast ka kui mudeli jääkide või prognoosivigade vektorist). Nii \mathbf{y} kui $\boldsymbol{\varepsilon}$ on juhuslikud vektorid. Eeldades, et tehtavad mõõtmistulemused pole süstemaatiliselt valed ehk nihkega ($E\boldsymbol{\varepsilon} = 0$ või, kui \mathbf{X} on juhuslik, $E(\boldsymbol{\varepsilon}|\mathbf{X}) = 0$) saame, et

$$E(\mathbf{y}|\mathbf{X}) = \mathbf{X}\boldsymbol{\beta}. \quad (1.2)$$

Lisaks eeldame, et juhuslikud vead $\boldsymbol{\varepsilon}$ pole korreleeritud,

$$(D(\mathbf{y}|\mathbf{X}) =) D(\boldsymbol{\varepsilon}) = \sigma^2\mathbf{I}. \quad (1.3)$$

Mõningate tulemuste tarvis läheb tarvis veel eelduseid juhuslike suuruste jaotuste kohta. Sellisel juhul eeldame, et $\boldsymbol{\varepsilon}$ on n -mõõtmelise normaaljaotusega juhuslik vektor, $\boldsymbol{\varepsilon} \sim N(0; \sigma^2\mathbf{I})$ ja sõltumatu mudeli maatriksist ($\boldsymbol{\varepsilon} \perp \mathbf{X}$). Selliste eelduste kehtides peab aga ka \mathbf{y} tinglik jaotus (tingimusel, et \mathbf{X} on antud) olema normaaljaotus:

$$\mathbf{y}|\mathbf{X} \sim N(\mathbf{X}\boldsymbol{\beta}; \sigma^2\mathbf{I}). \quad (1.4)$$

Tihti vaadeldakse praktikas ka situatsioone, kus \mathbf{X} on uurija poolt fikseeritavad/määratavad katsetingimused, seega pole maatriksi \mathbf{X} elemendid juhuslikud. Sellisel juhul taandub jaotuse eeldus 1.4 nõudeks, et uuritav tunnus \mathbf{y} oleks normaaljaotusega:

$$\mathbf{y} \sim N(\mathbf{X}\boldsymbol{\beta}; \sigma^2\mathbf{I}). \quad (1.5)$$

Näide 1.1 *Lihtne lineaarne regressioon.*

Vaatame regressioonmudelit

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, 6,$$

kus $(x_1, x_2, \dots, x_6) = (1, 2, 3, 4, 5, 6)$ ja mudeli vead ε_i on sõltumatud juhuslikud suurused jaotusega $\varepsilon_i \sim N(0; \sigma^2)$. Maatrikskujul kirjapandult näeks antud regressioonimudel välja järgmine:

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ y_5 \\ y_6 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & 2 \\ 1 & 3 \\ 1 & 4 \\ 1 & 5 \\ 1 & 6 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \\ \varepsilon_6 \end{bmatrix}$$

$$\mathbf{y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon}.$$

Näide 1.2 *Ruutseos x -i ja y -i vahel.*

Vaatame veidi keerukamat regressioonmudelit:

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i, \quad i = 1, \dots, 6,$$

Kui vaatlused oleksid samad mis eelmises näites, siis näeks antud regressioonmudel maatrikskujul välja järgmine:

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ y_5 \\ y_6 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 4 \\ 1 & 3 & 9 \\ 1 & 4 & 16 \\ 1 & 5 & 25 \\ 1 & 6 & 36 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \\ \varepsilon_6 \end{bmatrix}$$

$$\mathbf{y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon}.$$

Näide 1.3 *Dispersioonanalüüs.*

Ühe faktoriga dispersioonanalüüsi mudeli

$$y_{ij} = \mu + \alpha_i + \varepsilon_{ij},$$

kus $i = 1 \dots 3$, $j = 1 \dots n_i$, $(n_1, n_2, n_3) = (3, 1, 2)$, saab maatrikskuju kirja panna järgmiselt:

$$\begin{bmatrix} y_{11} \\ y_{12} \\ y_{13} \\ y_{21} \\ y_{31} \\ y_{32} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \alpha_3 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \\ \varepsilon_6 \end{bmatrix}$$

$$\mathbf{y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon}.$$

Peatükk 2

Mudeli parameetrite hindamine

Mudeli parameetrite hindamiseks on mitmeid erinevaid võimalusi. Ühel viisil leitud hinnangutel on ühed head omadused, teisel viisil leitud hinnangutel jälle teised head omadused. Käesolevas peatükis hindame lineaarse mudeli parameetreid kolmel erineval viisil — vähimruutude meetodil; suurima tõepära meetodil ja parima lineaarse nihketa hinnangu abil.

2.1 Vähimruutude hinnang

Vähimruutude meetodi puhul leitakse mudeli parameetrite β hinnang $\hat{\beta}$ selliselt, et tekkivate prognoosivigade $e = \mathbf{y} - \mathbf{X}\hat{\beta}$ ruutude summa $\sum_{i=1}^n e_i^2 = \mathbf{e}^T \mathbf{e}$ oleks minimaalne; teisisõnu minimeeritakse avaldise

$$S(\beta) = (\mathbf{y} - \mathbf{X}\beta)^T(\mathbf{y} - \mathbf{X}\beta)$$

väärtus β järgi.

Funktsiooni $S(\beta)$ miinimumi leidmiseks leiame esmalt tuletise vektori β järgi:

$$\begin{aligned} \frac{\partial S(\beta)}{\partial \beta} &= \frac{\partial(\mathbf{y}^T \mathbf{y} + \beta^T \mathbf{X}^T \mathbf{X} \beta - 2\mathbf{y}^T \mathbf{X} \beta)}{\partial \beta} \\ &= 2\beta^T \mathbf{X}^T \mathbf{X} - 2\mathbf{y}^T \mathbf{X}, \end{aligned}$$

võrdsustame leitud tuletise nulliga ja teisendame veidi saadud võrrandisüs-

teemi:

$$\begin{aligned} \frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} \Big|_{\boldsymbol{\beta}=\hat{\boldsymbol{\beta}}} &= 0 \\ 2\hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{X} - 2\mathbf{y}^T \mathbf{X} &= 0 \\ \mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\beta}} &= \mathbf{X}^T \mathbf{y}. \end{aligned} \quad (2.1)$$

Kui maatriks $(\mathbf{X}^T \mathbf{X})$ on pööratav, siis saame võrrandisüsteemi (2.1) lahendiks

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}.$$

Paraku pole maatriks $\mathbf{X}^T \mathbf{X}$ sageli pööratav — isegi näites 1.3 toodud lihtsa dispersioonanalüüsi mudeli korral pöördmaatriksit $(\mathbf{X}^T \mathbf{X})^{-1}$ ei eksisteeri.

Mida siis teha? Kui otsime lahendeid võrrandisüsteemile $\mathbf{A}\mathbf{x} = \mathbf{b}$, siis juhul, kui lahend leidub, avaldub ta kujul $\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}$, kus \mathbf{A}^{-1} tähistab maatriksi \mathbf{A} üldistatud pöördmaatriksit (\mathbf{A}^{-1} on maatriksi \mathbf{A} üldistatud pöördmaatriks, kui $\mathbf{A} = \mathbf{A}\mathbf{A}^{-1}\mathbf{A}$). Tasub tähele panna, et selline lahend pole üldjuhul üheselt määratud — kuna üldistatud pöördmaatriks ei pruugi olla üheselt määratud. Seega, kui võrrandisüsteem (2.1) on lahenduv, avaldub lahend kujul

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-} \mathbf{X}^T \mathbf{y}. \quad (2.2)$$

Leitud vähimruutude hinnang $\hat{\boldsymbol{\beta}}$ on üheselt määratud vaid juhul, kui maatriks $\mathbf{X}^T \mathbf{X}$ on pööratav. Kui aga $\mathbf{X}^T \mathbf{X}$ on kõdunud, siis eksisteerib rohkem kui üks lahend. Täpsemalt, iga $\hat{\boldsymbol{\beta}}$, mis avaldub kujul

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-} \mathbf{X}^T \mathbf{y} + (\mathbf{I} - (\mathbf{X}^T \mathbf{X})^{-} \mathbf{X}^T \mathbf{X}) \mathbf{u},$$

kus \mathbf{u} on suvaline n -mõõtmeline vektor, osutub samuti võrrandisüsteemi 2.1 lahendiks.

Kuidas jääb võrrandisüsteemi lahenduvuse küsimusega? Selgub, et vaadeldav võrrandisüsteem on alati lahenduv. Paraku läheb lahenduvuse korrektseks näitamiseks vaja mõningaid tehnilisi oskuseid ja abitulemusi. Sestap lükkame tõestuse korrektse vormistamise ja vähimruutude hinnangu omadustega tutvumise seniks edasi, kuni oleme tõestanud kõik vajalikud abitulemused. Kirjutame siinkohal vaid välja vähimruutude meetodil saadud hinnangud \mathbf{y} -le (või \mathbf{y} keskväärtusele) ja anname ka valemi prognoosivigade

arvutamiseks:

$$\begin{aligned}\hat{\mathbf{y}} &= \mathbf{X}\hat{\boldsymbol{\beta}} \\ &= \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{y} \\ \\ \mathbf{e} &= \mathbf{y} - \hat{\mathbf{y}} \\ &= (\mathbf{I} - \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T)\mathbf{y}.\end{aligned}$$

Kuna maatriksit $\mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T$ läheb antud kursuse raames sageli vaja, siis võtame tema jaoks kasutusele uue tähise:

$$\mathbf{P}_{\mathbf{X}} := \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T. \quad (2.3)$$

Kasutades uudset tähistus võime kirjutada: $\hat{\mathbf{y}} = \mathbf{P}_{\mathbf{X}}\mathbf{y}$ ja $\mathbf{e} = (\mathbf{I} - \mathbf{P}_{\mathbf{X}})\mathbf{y}$.

Muuseas, märka erinevust tähistustes: $\boldsymbol{\varepsilon} = \mathbf{y} - \mathbf{X}\boldsymbol{\beta}$; $\mathbf{e} = \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}$.

Kuna maatriksit $\mathbf{P}_{\mathbf{X}}$ kohtame lineaarsete mudelitega tegeledes korduvalt ja tal on kanda väga tähtis roll siis pühendame järgneva peatüki/loengu maatriksi $\mathbf{P}_{\mathbf{X}}$ matemaatiliste omadustega tutvumisele. Teades veidi paremini kuidas antud maatriks valemis kasutatakse lihtsustab tunduvalt meie edasist elu ja tuletuskäike.