

- **Luennoija:** Pentti Saikkonen
- **Tyyppi ja laajuus:** Aineopinnot, 5 op
- **Luentoajat:** IV periodi, to 14-16, D123 ja pe 12-14, C124
- **Suoritustapa:** Kurssikoe viikolla 9.5.-13.5. tai yleistentti 24.5.
- **Laskuharjoitukset:** Petri Aaltonen
  - To 12-14, B322 (28.4. C129)
  - Pe 10-12, B322
  - Lisäpisteitä harjoitustehtävien ratkaisemisesta saa 1, 2, 3 tai 4, jos ratkaistujen tehtävien määrä on vastaavasti 20, 40, 60 tai 80 prosenttia.

- **Esitietovaatimukset**

- Tilastollisen päättelyn kurssi sekä sen vaatimat esitiedot (Todennäköisyyslaskennan kurssi ja perusvalmiudet yhden ja useamman muuttujan differentiaali- ja integraalilaskennassa).
- Lineaarialgebran ja matriisilaskennan tuntemus on lisäksi **välttämätöntä** (esim. kurssit Lineaarialgebra ja matriisilaskenta I ja II, ja mielellään myös Matriisilaskentaa tilastotieteilijöille)

- **Sisältö:** Kurssilla käydään läpi lineaaristen mallien keskeinen teoria eli parametrien estimointi ja testaus sekä luottamusvälien muodostaminen ja niihin liittyvä jakaumateoria. Lisäksi tarkastellaan varianssianalyysia.

- **Kurssimateriaali:** Luentomoniste (liitteiden materiaali oletetaan pääosin tunnetuksi). Oheislukemistona voi käyttää seuraavia teoksia.
- Matriisialgebra:
  - Abadir, K. ja J. Magnus (2005): Matrix Algebra.
  - Searle, S.R. (1982): Matrix Algebra Useful for Statistics.
  - Schott, J. R. (2005): Matrix Analysis for Statistics.
- Lineaarisen mallin teoria:
  - Seber, G.A.F. ja A.J. Lee (2003): Linear Regression Analysis, 2.laitos.

# Lineaarisen mallin määrittely

## Yksinkertainen esimerkki

- Peltotilkut  $i = 1, \dots, n$
- Lannoitemäärät  $x_1, \dots, x_n$
- Satomäärät  $y_1, \dots, y_n$
- Mikä on lannoituksen vaikutus odotettavissa olevaan satomäärään?
- Oletetaan satomääriä vastaavista sm:sta
  - $Y_1, \dots, Y_n$  ||| eli riippumattomuus
  - $\mu_i := E(Y_i) = \beta_1 + \beta_2 x_i$  odotusarvon lineaarisuus
  - $\text{Var}(Y_i) = \sigma^2 \forall i$  varianssin koko ei riipu lannoitemäärästä
- Tilanne voidaan kuvata yhtälöllä

$$Y_i = \beta_1 + \beta_2 x_i + \varepsilon_i, \quad i = 1, \dots, n,$$

jossa sm:t  $\varepsilon_1, \dots, \varepsilon_n$  ovat ei-havaittavia, ||| ja toteuttavat

$$E(\varepsilon_i) = 0, \quad \text{Var}(\varepsilon_i) = \sigma^2 \forall i$$

# Lineaarisen mallin määrittely

## Yksinkertainen esimerkki

- Kuvattaessa lannoituksen vaikutusta odotettavissa olevaan satomäärään päädyttiin siis yhtälöön

$$Y_i = \beta_1 + \beta_2 x_i + \varepsilon_i, \quad i = 1, \dots, n,$$

jossa sm:t  $\varepsilon_1, \dots, \varepsilon_n$  ovat ei-havaittavia, || ja toteuttavat

$$E(\varepsilon_i) = 0, \quad \text{Var}(\varepsilon_i) = \sigma^2 \quad \forall i$$

- Sm:t  $\varepsilon_1, \dots, \varepsilon_n$  voidaan tulkita havaituissa satomäärissä ilmeneväksi 'puhtaaksi satunnaisvaihteluksi' tai selitysvirheeksi, joka ei selity lannoitemäärällä.
- Edellä esitettyä yhtälöä kutsutaan *yhden selittävän muuttujan lineaariseksi regressiomalliksi*.
- Tiukasti tilastollisen päättelyn näkökulmasta, ei kysymyksessä ole vielä kuitenkaan tilastollinen malli, jollainen vaatii havaintojen yhteistodennäköisyysjakauman ja parametriavaruuden spesifioinnin.

# Lineaarisen mallin määrittely

## Yksinkertainen esimerkki

Klassinen lineaarinen malli perustuu olettaa normaalijakaumaan ja tilastollinen malli saadaan olettamalla

$$Y_1, \dots, Y_n \quad \underline{\quad} \quad Y_i \sim N(\beta_1 + \beta_2 x_i, \sigma^2), \quad \beta_1, \beta_2 \in \mathbb{R}, \quad \sigma^2 > 0$$

tai yhtäpitävästi

$$Y_i = \beta_1 + \beta_2 x_i + \varepsilon_i, \quad i = 1, \dots, n, \quad \beta_1, \beta_2 \in \mathbb{R}, \quad \sigma^2 > 0$$

$$\varepsilon_1, \dots, \varepsilon_n \quad \underline{\quad} \quad , \quad \varepsilon_i \sim N(0, \sigma^2)$$

Tarkasteltavassa esimerkkitapauksessa oletus  $\beta_1 > 0$  tuntuisi järkevältä, mutta johtaa mutkikkaampaa malliin, joka ei sisälly klassiseen lineaariseen malliin.

# Lineaarisen mallin määrittely

## Yksinkertainen esimerkki

- Yhden selittävän muuttujan lineaarinen regressiomallissa

$$Y_1, \dots, Y_n \quad \underline{\parallel} \quad Y_i \sim N(\beta_1 + \beta_2 x_i, \sigma^2), \quad \beta_1, \beta_2 \in \mathbb{R}, \quad \sigma^2 > 0.$$


selittävien muuttujien havaintoja  $x_1, \dots, x_n$  ei tulkita satunnaisiksi (loogista tarkasteltavassa tapauksessa).

- Jos selittävät muuttujat olisivat satunnaisia, täytyisi tilastollinen malli periaatteessa laajentaa koskemaan sv:ta  $[Y_i \ X_i]'$ ,  $i = 1, \dots, n$ .
- Usein selitettäviä muuttujia  $Y_1, \dots, Y_n$  voidaan tarkastella ehdollisesti ehdolla  $(X_1, \dots, X_n) = (x_1, \dots, x_n)$ , jolloin edellä esitetty malli soveltuu.
- Usein tarvitaan useita selittäviä muuttujia

# Lineaarisen mallin määrittely

Yksinkertainen esimerkki

Äitien ja tyttärien pituudet (tuumissa):  $n = 30$ , katkoviiva 45 asteen suora





# Yleinen lineaarinen malli

**Tausta:** Aineiston muuttujista yksi on luonteeltaan *selitettävä* ja loput sen vaihtelua *selittäviä* muuttujia eli kaaviona

Havainto yksikkö	Selitettävä m:t; $y$	Selittävät m:t; $x_1, \dots, x_p$
1	$y_1$	$x_{11}, \dots, x_{1p}$
$\vdots$	$\vdots$	$\vdots$
$n$	$y_n$	$x_{n1}, \dots, x_{np}$

Lineaarisisessa mallissa selittävän muuttujan vaikutus selitettävään muuttujaan oletetaan (tietyssä mielessä) *lineaariseksi*.

# Yleinen lineaarinen malli

- Lineaarisen mallin määritelmä voidaan perustaa yhtälöön

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

jossa  $Y_i$  on havaittava sm,  $x_{i1}, \dots, x_{ip}$  ovat havaittavia ja ei-satunnaisia (eli kiinteitä),  $\varepsilon_i$  on ei-havaittava sm ja  $\beta_1, \dots, \beta_p$  ovat tuntemattomia parametreja.

- $\varepsilon_i$  on ns. *virhe(termi)* eli se osa  $Y_i$ :stä, jota mallin systemaattinen osa tai rakenne  $\beta_1 x_{i1} + \cdots + \beta_p x_{ip}$  ei kykyne selittämään
- Linearisuus oletetaan parametrien  $\beta_1, \dots, \beta_p$  suhteen ja virhetermi lisätään systemaattiseen osaan additiivisesti.
  - Esimerkiksi

$$Y_i = \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i, \quad i = 1, \dots, n,$$

on vaaditulla tavalla lineaarinen

- Lineaariseen malliin voidaan päätyä lähtemällä oletuksesta

$$Y_1, \dots, Y_n \underline{\parallel}, Y_i \sim N(\mu_i, \sigma^2)$$

ja olettamalla odotusarvoille  $\mu_i$  (esim. taustatiedon perusteella) rakenne  $\mu_i = \mathbf{x}'_i \boldsymbol{\beta}$ , jossa  $\mathbf{x}'_i = [x_{i1} \cdots x_{ip}]$  ja  $\boldsymbol{\beta} = [\beta_1 \cdots \beta_p]'$ .

- Miksi vaihtoehtoinen muotoilu ( $i = 1, \dots, n$ )

$$Y_i = \mathbf{x}'_i \boldsymbol{\beta} + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \underline{\parallel}, \quad \varepsilon_i \sim N(0, \sigma^2)$$

ja virhetermi  $\varepsilon_i$ ?

- Yksi syy on, että tämä on toisinaan luonteva muotoilu.
- Toinen, että käsitteet *residuaali*  $\hat{\varepsilon}_i = y_i - \mathbf{x}'_i \hat{\boldsymbol{\beta}}$  ja *sovite*  $\hat{\mu}_i = \mathbf{x}'_i \hat{\boldsymbol{\beta}} = \hat{y}_i$  ovat hyödyllisiä ( $\hat{\boldsymbol{\beta}}$  on parametrin  $\boldsymbol{\beta}$  estimaatti).
- Residuaali on teoreettisen virheen  $\varepsilon_i = Y_i - \mathbf{x}'_i \boldsymbol{\beta}$  empiirinen vastine ja sovite on mallin systemaattisen osan  $\mu_i = \mathbf{x}'_i \boldsymbol{\beta}$  empiirinen vastine.

- Residuaalit  $\hat{\varepsilon}_i = y_i - \mathbf{x}'_i \hat{\boldsymbol{\beta}}$  sisältävät ilmeisestikin informaatiota virheiden  $\varepsilon_i = Y_i - \mathbf{x}'_i \boldsymbol{\beta}$  varianssista eli parametrasta  $\sigma^2 = \text{Var}(\varepsilon_i) = \text{Var}(Y_i)$ .
- Residuaalien avulla voidaan myös tutkia mallin oletusten paikkansapitävyyttä yleensä helpommin kuin alkuperäisten havaintojen  $y_1, \dots, y_n$  avulla.
- Tutkittavia oletuksia:
  - Onko  $\text{Var}(Y_i) = \text{Var}(\varepsilon_i)$  vakio kuten oletetaan?
  - Pätee oletettu riippumattomuus  $Y_1, \dots, Y_n \perp\!\!\!\perp \Leftrightarrow \varepsilon_1, \dots, \varepsilon_n \perp\!\!\!\perp$  ?
  - Pätee oletettu normalisuus  $Y_i \sim N(\mathbf{x}'_i \boldsymbol{\beta}, \sigma^2) \Leftrightarrow \varepsilon_i \sim N(0, \sigma^2)$  ?

- Mallin matriisiesitys

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1p} \\ & \vdots & \\ x_{n1} & \cdots & x_{np} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_p \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

eli

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\beta} \in \mathbb{R}^p, \quad \sigma^2 > 0,$$

jossa  $\varepsilon_1, \dots, \varepsilon_n \perp\!\!\!\perp$ ,  $\varepsilon_i \sim N(0, \sigma^2) \Leftrightarrow \boldsymbol{\varepsilon} \sim N(0, \sigma^2 \mathbf{I}_n)$ .

- Yhtäpitävä muotoilu

$$\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n), \quad \boldsymbol{\beta} \in \mathbb{R}^p, \quad \sigma^2 > 0.$$

- Lisäoletus: Matriisi  $\mathbf{X}$  ( $n \times p$ ) täyttää sarakeastetta eli  $r(\mathbf{X}) = p$ .

# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

- Riippumaton otos normaalijakaumasta (vrt. tilastollinen päättely).

$$Y_1, \dots, Y_n \text{ i.i.d.}, Y_i \sim N(\mu, \sigma^2)$$

- 

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \mu + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

eli

$$\mathbf{Y} = \mathbf{1}_n \mu + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n) \quad \Leftrightarrow \quad \mathbf{Y} \sim N(\mathbf{1}_n \mu, \sigma^2 \mathbf{I}_n)$$

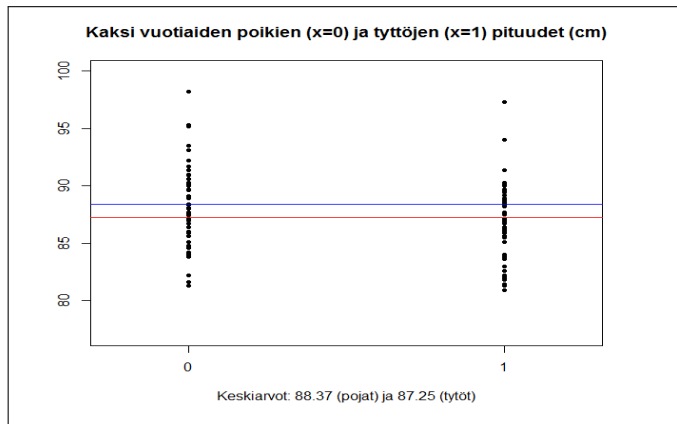
Matriiseiksi  $\mathbf{X}$  tulee siten vektori  $\mathbf{1}_n = [1 \ \cdots \ 1]'$  ( $n \times 1$ ).

- Kiinnostava hypoteesi  $H_0 : \mu = \mu_0$

# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

Kaksivuotiaiden poikien ( $x = 0$ ) ja tyttöjen ( $x = 1$ ) pituudet (cm)  
 $n_1 = 66$ ,  $n_2 = 70$ . Kysymys: Eroavatko tyttöjen ja poikien keskipituudet?



# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

- Kahden odotusarvoltaan (mahdollisesti) poikkeavan riippumattoman normaalisen otoksen malli eli

$$Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim}, Y_i \sim \begin{cases} N(\mu_1, \sigma^2), & \text{kun } i = 1, \dots, n_1 \\ N(\mu_2, \sigma^2), & \text{kun } i = n_1 + 1, \dots, n_1 + n_2 = n. \end{cases}$$

- 

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_{n_1} \\ Y_{n_1+1} \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ \vdots & \vdots \\ 1 & 0 \\ 0 & 1 \\ \vdots & \vdots \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_{n_1} \\ \varepsilon_{n_1+1} \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

eli

$$\mathbf{Y} = \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0} \\ \mathbf{0} & \mathbf{1}_{n_2} \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n); \quad H_0: \mu_1 = \mu_2$$



# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

- *Yksisuuntainen varianssianalyysimalli.* Havaintoina on  $p$  riippumatonta otosta jakaumista  $N(\mu_j, \sigma^2)$  ( $j = 1, \dots, p$ ).
- Esimerkiksi vehnälajikkeiden  $A_1, \dots, A_p$  satoisuuden tutkiminen, kun niitä viljellään samoissa olosuhteissa.
- Kiinnostuksen kohteena on odotusarvoissa  $\mu_1, \dots, \mu_p$  mahdollisesti ilmenevät erot; esim.  $H_0 : \mu_1 = \dots = \mu_p$
- *Kaksisuuntainen varianssianalyysimalli.* Esimerkiksi vehnälajikkeita  $A_1$  ja  $A_2$  lannoitetaan kahta eri lannoitetta  $B_1$  ja  $B_2$  käyttäen, jolloin havainnot peräisin neljästä ryhmästä.
- Mallin avulla voidaan tutkia onko satomäärissä eroja eri ryhmien välillä ja johtuvatko mahdolliset erot vehnälajikkeesta, lannoitteesta vai niiden yhteisvaikutuksesta.
- Näissä malleissa selittävät muuttujat ovat ryhmää osoittavia indikaattoreita.

# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

- *Usean selittäjän lineaarinen regressiomalli*

$$Y_i = \beta_1 + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i, \quad i = 1, \dots, n, \quad \beta \in \mathbb{R}^p, \sigma^2 > 0.$$

$\beta_1$  ns. (regressio)vakio ja  $\beta_j$  ( $j = 2, \dots, p$ ) ns. regressiokerroin, joka kuvaa paljonko selitettävä muuttuja (tai sen odotusarvo) muuttuu, kun  $j$ :nnen selittäjän arvo muuttuu yhden yksikön ja muiden selittäjien arvot pysyvät ennallaan.

- Saadaan yleisestä mallista valitsemalla  $x_{i1} = 1$ , joten

$$\mathbf{X} = \begin{bmatrix} 1 & x_{12} & \cdots & x_{1p} \\ & & \vdots & \\ 1 & x_{n2} & \cdots & x_{np} \end{bmatrix}$$

# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

- Samassa mallissa voi olla sekä kvantitatiivisia selittäjiä että kvalitatiivisia ryhmää osoittavia indikaattoreita.
- Tutkitaan esimerkiksi vehnälaajikkeiden  $A_1$  ja  $A_2$  satoisuutta, kun molempia lannoitetaan samaa lannoitetta käyttäen:

$$Y_1, \dots, Y_n \quad \underline{\underline{\parallel}}, \quad Y_i \sim \begin{cases} N(\beta_1 + \beta_3 x_i, \sigma^2), & \text{kun } i = 1, \dots, n_1 \\ N(\beta_2 + \beta_3 x_i, \sigma^2), & \text{kun } i = n_1 + 1, \dots, n_1 + n_2 \end{cases}$$


eli

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_{n_1} \\ Y_{n_1+1} \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & 0 & x_1 \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{n_1} \\ 0 & 1 & x_{n_1+1} \\ \vdots & \vdots & \vdots \\ 0 & 1 & x_n \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_{n_1} \\ \varepsilon_{n_1+1} \\ \vdots \\ \varepsilon_n \end{bmatrix}.$$

# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

Tyttöjen (musta) ja poikien (ympyrä) pituudet 9 ja 18 v. ikäisinä (cm)  
 $n_1 = 66$ ,  $n_2 = 70$ . Kysymys: Onko tyttöjen ja poikien kasvuvauhdissa eroja?



# Yleinen lineaarinen malli

## Lineaarisen mallin erikoistapauksia

- Joskus epälineaarinen malli voi olla *linearisoituva*:

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

jossa muuttujat oletetaan positiivisiksi.

- Ottamalla (luonnollinen) logaritmi puolittain päädytään yhtälöön

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

eli (merkintöjä vaille) usean selittäjän lineaarinen regressiomalli.

- Tällaiset ns. multiplikatiiviset mallit ovat tavallisia taloudellisissa sovelluksissa mallinnettaessa esimerkiksi jonkin tuotteen kysyntää.

# Yleinen lineaarinen malli

Yhteenveto lineaarisen mallin määrittelystä

- Lineaarisen mallin määritelmä voidaan perustaa yhtälöön

$$\begin{aligned} Y_i &= \beta_1 x_{i1} + \cdots + \beta_p x_{ip} + \varepsilon_i \\ &= \mathbf{x}'_i \boldsymbol{\beta} + \varepsilon_i, \quad i = 1, \dots, n, \end{aligned}$$

jossa  $Y_i$  on havaittava sm,  $\mathbf{x}_i = [x_{i1} \cdots x_{ip}]'$  on havaittava ja ei-satunnainen (eli kiinteitä),  $\varepsilon_i$  on ei-havaittava sm ja  $\beta_1, \dots, \beta_p$  ovat tuntemattomia parametreja.

- $\varepsilon_i$  on ns. *virhe(termi)* eli se osa  $Y_i$  stä, jota mallin systemaattinen osa tai rakenne  $\beta_1 x_{i1} + \cdots + \beta_p x_{ip}$  ei kykyne selittämään.
- Tilastollista mallia varten oletetaan

$$\varepsilon_1, \dots, \varepsilon_n \underline{\parallel}, \quad \varepsilon_i \sim N(0, \sigma^2) \Leftrightarrow Y_1, \dots, Y_n \underline{\parallel} Y_i \sim N(\mathbf{x}'_i \boldsymbol{\beta}, \sigma^2)$$

# Yleinen lineaarinen malli

Yhteenveto lineaarisen mallin määrittelystä

- Mallin matriisiesitys

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1p} \\ & \vdots & \\ x_{n1} & \cdots & x_{np} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_p \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

eli

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon},$$

jossa  $\varepsilon_1, \dots, \varepsilon_n \stackrel{\text{iid}}{\parallel}, \varepsilon_i \sim N(0, \sigma^2) \Leftrightarrow \boldsymbol{\varepsilon} \sim N(0, \sigma^2 \mathbf{I}_n)$ .

- Nyt malli voidaan määritellä lyhyesti kirjoittamalla

$$\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n), \quad \boldsymbol{\beta} \in \mathbb{R}^p, \sigma^2 > 0.$$

- Lisäoletus: Matriisi  $\mathbf{X}$  ( $n \times p$ ) täyttää sarakeastetta eli  $r(\mathbf{X}) = p$ .

# Yleinen lineaarinen malli

Yhteenveto lineaarisen mallin määrittelystä

- Lineaarinen malli voidaan siis määrittellä kahdella yhtäpitävällä tavalla:

$$(1) \quad \mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n), \quad \boldsymbol{\beta} \in \mathbb{R}^p, \sigma^2 > 0.$$

tai

$$(2) \quad Y_1, \dots, Y_n \quad \underline{\parallel} \quad Y_i \sim N(\mathbf{x}'_i \boldsymbol{\beta}, \sigma^2), \quad \boldsymbol{\beta} \in \mathbb{R}^p, \sigma^2 > 0$$

- Uskottavuusfunktio voidaan johtaa kumpaa tahansa käyttäen.
- Lisäoletus, että matriisi  $\mathbf{X}$  ( $n \times p$ ) on täyttä sarakeastetta eli  $r(\mathbf{X}) = p$  ei vaikuta uskottavuusfunktion johtoon.