

Forsørig model


$$y = v(x_1, \dots, x_p) + u$$

\uparrow obs. værdi af stok. var. $\underbrace{\hspace{10em}}$ forklarende variable (ikke stokastiske) \nwarrow stokastisk led (ikke direkte observerbart)

bemærk $\underbrace{\hspace{15em}}$ sum af systematisk og stokastisk led

regressionsmodel

eks.



\uparrow
sluttes til tiden $t=0$

$$v + Ri = E, \quad i = Cv'$$

$$v' + \frac{1}{RC}v = \frac{E}{RC}, \quad RC = T$$

hom. løsn.: $\frac{v'}{v} = -\frac{1}{T}$

$$\Rightarrow \ln v = -\frac{t}{T} + k_1$$

$$\Rightarrow v = k e^{-\frac{t}{T}}$$

part. løsn.: $v_p = E$ (ses ved indsættelse)

beg. bet. $v(0) = 0 \Rightarrow k = -v_p(0) = -E$

altså $v = E(1 - e^{-\frac{t}{T}})$, $T = RC$, $t \geq 0$

mere realistisk: $v = E(1 - e^{-\frac{t}{T}}) + u$

E og T forsk. var.

bemærk ikke-lineært udtryk

ved Taylorudvikling om $t = t_0$ kan man

$$v \approx \underbrace{E(1 - e^{-\frac{t_0}{T}})}_{\beta_0} + \underbrace{\frac{E}{T} e^{-\frac{t_0}{T}}}_{\beta_1} (t - t_0) - \underbrace{\frac{E}{2T^2} e^{-\frac{t_0}{T}}}_{\beta_2} (t - t_0)^2 + \dots$$

lineært i β_0, β_1 og β_2

Når $r(\cdot)$ er lineær i β_1, \dots, β_p bliver y udtrykt

$$y = \beta_1 x_1 + \dots + \beta_p x_p + u,$$

hvor β_1, \dots, β_p er ukendte parametre

Egenskaber ved modellen

- simpel
- kan ofte argumenteres ud fra erfaring
- modellen kan i visse tilfælde fremkomme efter transformation, fx

$$y = a b^x \Rightarrow \ln y = \ln a + x \ln b \Leftrightarrow z = \alpha + \beta x$$
- kun linearitet i parametre nødvendig
- evt. 'linearisering' lokalt ved Taylor-udvikling
- simpel at behandle matematiske
- både kvantitative og kvalitative størrelser kan optræde som for- eller afhængende variable

Den lineære model

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

uafh.

x_{ik} er i 'te verdi af den k 'te forkl. var.

kort notation: $Y = X\beta + U$

↑

kaldes designmatrix

format $n \times p$, $n \geq p$

$$\begin{aligned} \text{Kraav: } E[U] &= 0 \\ \text{Var}[U] &= \sigma^2 I \end{aligned} \quad \left. \vphantom{\begin{aligned} E[U] \\ \text{Var}[U] \end{aligned}} \right\} \begin{array}{l} \text{anden ordens} \\ \text{hypotesen} \end{array}$$

$$\begin{aligned} \text{Heraf } E[Y] &= X\beta \\ \text{Var}[Y] &= \sigma^2 I \end{aligned}$$

Ønske: At bestemme β , så $\|y - \mu\|$ minimeres ($\mu = X\beta$)

Ækvivalent: At bestemme β , så $\|y - \mu\|^2$ minimeres

$$\begin{aligned} \text{Bemærk: } \|y - \mu\|^2 &= (y - \mu)^T (y - \mu) \\ &= (y - X\beta)^T (y - X\beta) \end{aligned}$$


Metoden kaldes mindste kvadraters metode

Geometrisk bestemmelse

$$\text{Bemærk } X\beta = \beta_1 x_1 + \dots + \beta_p x_p$$

$$\text{dvs. } X\beta \in \text{sp}\{x_1, \dots, x_p\} = C(X)$$

↑
 μ -dim. underrum af \mathbb{R}^m ,
 når $\text{rang } X = \mu$.



$$\begin{aligned} y &\in \mathbb{R}^m \\ \hat{\mu} &\in C(X) \\ y - \hat{\mu} &\in (C(X))^\perp \end{aligned}$$

$$(y - \hat{\mu})^T X = 0 \Rightarrow (y - X\hat{\beta})^T X = 0$$

$$\Leftrightarrow X^T (y - X\hat{\beta}) = 0$$

$$\Leftrightarrow \underbrace{X^T X}_{\text{normal equations}} \hat{\beta} = X^T y$$

kaldes normallikningerne

med $\text{rang } X = r$ får vi entydig

løsning:

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

$$\text{heraf } \hat{\mu} = X\hat{\beta} = X(X^T X)^{-1} X^T y = Py$$

$P = X(X^T X)^{-1} X^T$ er projektionsmatrix
for ortogonalprojektion på $C(X)$.

Bemærk, at

$$- P^T = P \quad (P \text{ sym.})$$

$$- P^2 = P \quad (P \text{ idempotent})$$

$$- \text{tr } P = \text{tr} (X(X^T X)^{-1} X^T)$$

$$= \text{tr} (X^T X (X^T X)^{-1})$$

$$= \text{tr } I_r$$

$$= r$$

$$\text{dvs. } \text{rang } P = \text{tr } P$$

Residualvektor

$$y - \hat{\mu} = y - Py = (I_n - P)y$$

$I_n - P$ er projektionsmatrix for
projektion på $(C(X))^\perp$

$$y = \hat{\mu} + (y - \hat{\mu}) \quad (\text{ortogonalt dekomposition})$$

$$\Rightarrow \|y\|^2 = \|\hat{\mu}\|^2 + \|y - \hat{\mu}\|^2$$

(Pythagoras)

Analytisk bestemmelse

$$\begin{aligned} & \frac{d}{d\beta} (y - X\beta)^T (y - X\beta) \\ &= \frac{d}{d\beta} (y^T y - 2y^T X\beta + \beta^T X^T X\beta) \\ &= -2X^T y + 2X^T X\beta = 2(X^T X\beta - X^T y) \\ &= 0 \quad \text{for} \quad X^T X\beta = X^T y \end{aligned}$$

des. normalligningen som før

$$\frac{d^2}{d\beta d\beta^T} (y - X\beta)^T (y - X\beta) = 2X^T X > 0$$

(pos. def.)

des. minimum

$$\left(\text{bemerk, at } \frac{d}{dx} Ax = A^T \text{ og } \frac{d}{dx} x^T Bx = 2Bx \right)$$

Mindste kvadratis estimer

$$\text{Vi har } \hat{\beta} = (X^T X)^{-1} X^T Y$$

$$\begin{aligned} \Rightarrow E[\hat{\beta}] &= (X^T X)^{-1} X^T E[Y] \\ &= (X^T X)^{-1} X^T X \beta \\ &= \beta, \end{aligned}$$

des. $\hat{\beta}$ er et centralt estimat for β .

$$\begin{aligned} \text{Var}[\hat{\beta}] &= (X^T X)^{-1} X^T \text{Var}[Y] X (X^T X)^{-1} \\ &= (X^T X)^{-1} X^T \sigma^2 I X (X^T X)^{-1} \\ &= \sigma^2 (X^T X)^{-1} \end{aligned}$$

$$\text{Heraf } E[\hat{\mu}] = X E[\hat{\beta}] = X \beta = \mu$$

$$\begin{aligned} \text{Var}[\hat{\mu}] &= X \text{Var}[\hat{\beta}] X^T \\ &= \sigma^2 X (X^T X)^{-1} X^T \\ &= \sigma^2 P \end{aligned}$$

Krav til konsistens af $\hat{\beta}$:

$$((X^T X)^{-1})_{ii} \rightarrow 0 \text{ for } n \rightarrow \infty$$

$$\text{bemerk } X^T X = \sum_{i=1}^n \tilde{x}_i \tilde{x}_i^T \quad *$$

$$\text{des. } (X^T X)^{-1} \rightarrow 0 \text{ for } n \rightarrow \infty$$

medmindre $\tilde{x}_i \rightarrow 0$ 'hurtigt'

(ikke-præcist argument)

* \tilde{x}_i består af komponenterne i i 'te rækkevektor i X

Estimat for σ^2

$$\text{Var}[U_i] = \sigma^2 \Rightarrow E[U_i^2] = \sigma^2$$

derfor valgs

$$\hat{\sigma}^2 = \frac{1}{n} \|y - \hat{\mu}\|^2 \quad (y - \hat{\mu} \text{ er residual-vektoren})$$

$$\begin{aligned} n \hat{\sigma}^2 &= (y - \hat{\mu})^T (y - \hat{\mu}) \\ &= ((I - P)y)^T (I - P)y \\ &= y^T (I - P)y \\ &= u^T (I - P)u \quad * \\ &= y^T (y - X\hat{\beta}) \end{aligned}$$

$$* \text{ idet } (I - P)\mu = \mu - P\mu = \mu - \mu = 0$$

$$\begin{aligned} E[n \hat{\sigma}^2] &= E[U^T (I - P)U] \\ &= 0^T (I - P)0 + \text{tr}((I - P) \text{Var } U) \\ &= 0 + \text{tr}(\sigma^2 (I - P)) \\ &= (n - p) \sigma^2 \end{aligned}$$

$$\text{dvs. } s^2 = \frac{n}{n - p} \hat{\sigma}^2 \text{ er et centralt}$$

estimat for σ^2

$$\text{dvs. } y = 1_n \mu + u \quad (n \text{ uafh. obs.})$$


$$(1_n^T 1_n) \mu = 1_n^T y \Leftrightarrow n \mu = \sum_i y_i$$

$$\begin{aligned} \Rightarrow \hat{\mu} &= \frac{n \bar{y}}{n} = \bar{y} \quad \wedge \quad \text{Var } \hat{\mu} = \sigma^2 (1_n^T 1_n)^{-1} \\ &= \frac{\sigma^2}{n} \end{aligned}$$

also $y = \beta_0 1_n + \beta_1 x + u$ (in obs.)

(simple linear regression)

$$X = \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \quad n \times 2$$



$$X^T X = \begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix} = \begin{bmatrix} n & n\bar{x} \\ n\bar{x} & \sum x_i^2 \end{bmatrix}$$

$$(X^T X)^{-1} = \frac{1}{n \sum x_i^2 - n^2 \bar{x}^2} \begin{bmatrix} \sum x_i^2 & -n\bar{x} \\ -n\bar{x} & n \end{bmatrix}$$

$$X^T y = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix} = \begin{bmatrix} n\bar{y} \\ \sum x_i y_i \end{bmatrix}$$

$$\hat{\beta} = \frac{1}{n S_{xx}} \begin{bmatrix} \sum x_i^2 & -n\bar{x} \\ -n\bar{x} & n \end{bmatrix} \begin{bmatrix} n\bar{y} \\ \sum x_i y_i \end{bmatrix}$$

$$= \frac{1}{n S_{xx}} \begin{bmatrix} n\bar{y} \sum x_i^2 - n\bar{x} \sum x_i y_i \\ -n^2 \bar{x} \bar{y} + n \sum x_i y_i \end{bmatrix}$$

$$= \frac{1}{S_{xx}} \begin{bmatrix} \bar{y} (\sum x_i^2 - n\bar{x}^2) - \bar{x} \sum x_i y_i + n\bar{x}^2 \bar{y} \\ \sum x_i y_i - n\bar{x} \bar{y} \end{bmatrix}$$

$$= \frac{1}{S_{xx}} \begin{bmatrix} \bar{y} S_{xx} - \bar{x} S_{xy} \\ S_{xy} \end{bmatrix} = \begin{bmatrix} \bar{y} - \frac{S_{xy}}{S_{xx}} \bar{x} \\ \frac{S_{xy}}{S_{xx}} \end{bmatrix}$$

also $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$ or $\hat{\beta}_1 = \frac{S_{xy}}{S_{xx}}$

ext. formulating:

$$z = x - \bar{x} 1_n \Rightarrow \bar{z} = \bar{x} - \bar{x} = 0$$

$$y = \alpha 1_n + \beta_2 z + u, \quad \alpha = \beta_0 + \beta_1 \bar{x}$$

$$\hat{\alpha} = \bar{y}, \quad \hat{\beta}_1 = \frac{S_{xy}}{S_{xx}}, \quad \hat{\alpha} \text{ and } \hat{\beta}_1 \text{ uncorrelated}$$

Stikprøvekorrelation

$$r = \frac{S_{xy}}{\sqrt{S_{xx} S_{yy}}} = \frac{\frac{1}{n-1} S_{xy}}{\sqrt{\frac{1}{n-1} S_{xx} \frac{1}{n-1} S_{yy}}} = \frac{s_{xy}}{s_x s_y}$$

Determinationskoefficienten

$$\begin{aligned} r^2 &= \frac{\| \hat{y} - \bar{y} 1_n \|^2}{\| y - \bar{y} 1_n \|^2} = \frac{\| (\bar{y} - \frac{S_{xy}}{S_{xx}} \bar{x}) 1_n + \frac{S_{xy}}{S_{xx}} x - \bar{y} 1_n \|^2}{\| y - \bar{y} 1_n \|^2} \\ &= \frac{\| \frac{S_{xy}}{S_{xx}} (x - \bar{x} 1_n) \|^2}{\| y - \bar{y} 1_n \|^2} = \frac{(\frac{S_{xy}}{S_{xx}})^2 \cdot S_{xx}}{S_{yy}} \\ &= \frac{S_{xy}^2}{S_{xx} S_{yy}} \end{aligned}$$

(r^2 er den brøkdelen af variationen, der kan forklares af modellen)

Gauss - Markov

Vi har $\hat{\beta} = (X^T X)^{-1} X^T Y$ med $E[\hat{\beta}] = \beta$

Antag $T = C^T Y$, hvor $E[T] = \beta$ for alle β
(C er $n \times r$)

Gauss - Markovs sætning: $\text{Var}[\hat{\beta}] \leq \text{Var}[T]$

Bevís = $\text{Var}[\hat{\beta}] = \sigma^2 (X^T X)^{-1}$

$\text{Var}[T] = C^T \sigma^2 I C = \sigma^2 C^T C$

bemærk $E[C^T Y] = \beta \Rightarrow C^T E[Y] = \beta$
 $\Rightarrow C^T X \beta = \beta \Rightarrow C^T X = I_n,$

der $\text{var}[\hat{\beta}]$ kan skrives

$$\text{var}[\hat{\beta}] = \sigma^2 C^T X (X^T X)^{-1} X^T C$$

$$= \sigma^2 C^T P C$$

$$\text{Var}[Y] - \text{var}[\hat{\beta}] = \sigma^2 C^T C - \sigma^2 C^T P C$$

$$= \sigma^2 C^T (I - P) C \geq 0$$

(pos. semi-definit)

Vælges $\eta = a^T \beta$, er $a^T \hat{\beta}$ et centralt
 estimeret for η , ifølge Gauss-Markov
 det centrale estimeret med mindst
 varians.

Særligt for $a = e_j$ får vi $e_j^T \beta = \beta_j$.
 $\hat{\beta}_j$ er derfor bedste lineære estimeret
 for β_j .

Middelkvadrater

Tilbage til $\|y\|^2 = \|\hat{\beta}\|^2 + \|y - \hat{\beta}\|^2$, som også
 kan skrives $y^T y = y^T P y + y^T (I - P) y$, hvor
 alle tre led er kvadratiske former (idet
 $y^T y = y^T I y$).

Bemærk $\text{rang } I = n$, $\text{rang } P = r$, $\text{rang } (I - P) = n - r$

De såkaldte middelmkwadrater defineres som

$$\frac{1}{n} y^T y, \quad \frac{1}{r} y^T P y, \quad \frac{1}{n-r} y^T (I - P) y$$

De tilsvarende stokastiske udtryk er

$$\frac{1}{n} Y^T Y, \quad \frac{1}{r} Y^T P Y, \quad \frac{1}{n-r} Y^T (I - P) Y$$

Middelværdierne af disse er

$$E\left[\frac{1}{n} Y^T Y\right] = \frac{1}{n} (\sigma^2 \text{tr } I + \mu^T \mu) = \sigma^2 + \frac{1}{n} \mu^T \mu$$

$$\begin{aligned} E\left[\frac{1}{r} Y^T P Y\right] &= \frac{1}{r} (\sigma^2 \text{tr } P + \mu^T P \mu) \\ &= \sigma^2 + \frac{1}{r} \mu^T P \mu \end{aligned}$$

$$E\left[\frac{1}{n-r} Y^T (I - P) Y\right] = \frac{1}{n-r} \sigma^2 \text{tr } (I - P) = \sigma^2$$