

**Tentamen för kursen**  
**Linjära statistiska modeller**  
**20 oktober 2022 14–19**

*Examinator:* Ola Hössjer, tel. 070/672 12 18, ola@math.su.se

*Återlämning:* Meddelas via kurshemsida och webbaserat kursforum.

*Tillåtna hjälpmedel:* Miniräknare och formelsamling delas ut vid tentamens-  
tillfället. Tabell över F-kvantiler återfinns nedan. Det gäller även att  
 $\chi_{0.05}^2(1) \approx 3.8$ .

Resonemang skall vara tydliga och lätta att följa. Varje korrekt och fullständigt  
löst uppgift ger 10 poäng. Följande gränser gäller för betygen A-E:

A	B	C	D	E
45	40	35	30	25

---

**Uppgift 1**

För att undersöka prisutvecklingen hos en viss typ av päron uppskattades  
det genomsnittliga kilopriset  $y_i$  i Sverige under nio på varandra följande  
år ( $x_1 = 2012, x_2 = 2013, \dots, x_9 = 2020$ ). Man ansatte en enkel linjär  
regressionsmodell

$$Y_i = \tilde{\alpha} + \beta(x_i - \bar{x}) + \varepsilon_i, \quad i = 1, \dots, 9,$$

där  $y_i$  är en observation av  $Y_i$ ,  $\bar{x} = \sum_{i=1}^9 x_i/9$  och  $\varepsilon_i \sim N(0, \sigma^2)$  är oberoende  
feltermar.

**a)** Beräkna en skattning av det förväntade kilopriset år 2022 om  $\bar{y} =$   
 $\sum_{i=1}^9 y_i/9 = 26.9$  och  $\sum_{i=1}^9 y_i(x_i - \bar{x}) = 27.3$ . (4 p)

**b)** Beräkna medelfelet  $d$  för skattningen i a), om kvadratsumman för varia-  
tionskällan "Residual" i variansanalystabellen ges av  $K_{vs} = 0.9274$ . (3 p)

**c)** Ange ett 95% konfidensintervall för det förväntade kilopriset år 2022.  
(Ledning: Intervallet innehåller kvantilen  $t_{0.025}(7) = 2.3646$ .) (3 p)

## Uppgift 2

Ett läkemedelsföretag har sedan länge astmamedicinen 1 på marknaden och vill undersöka om en annan, nyutvecklad medicin 2 har samma effekt. För respektive medicin uppmättes syreupptagningsförmågan  $Y$  hos 5 patienter en timme efter att de tagit en dos (olika för de 5 patienterna). Sedan antogs en linjär dos respons-kurva för respektive medicin. Det svarar mot en linjär modell

$$Y_{ij} = \alpha_i + \beta_i x_j + \varepsilon_{ij}, \quad i = 1, 2, \quad j = 1, \dots, 5, \quad (1)$$

för syreupptagningsförmågan hos den patient som tagit dosen  $x_j$  mg av medicin  $i$ , där feltermerna  $\varepsilon_{ij} \sim N(0, \sigma^2)$  antas vara oberoende.

a) Ange observationsvektor  $\mathbf{Y}$ , designmatris  $\mathbf{A}$ , parametervektor  $\boldsymbol{\theta}$  och feltermsvektor  $\boldsymbol{\varepsilon}$  för den linjära modellen

$$\mathbf{Y} = \mathbf{A}\boldsymbol{\theta} + \boldsymbol{\varepsilon}.$$

som svarar mot (1). (Ledning:  $\boldsymbol{\theta}$  har fyra element, två intercept och två effektparametrar.) (3 p)

b) Nollhypotesen

$$H_0 : \alpha_1 = \alpha_2, \quad \beta_1 = \beta_2$$

att de två medicinerna har samma effekt kan formuleras som  $\boldsymbol{\theta} = \mathbf{B}\boldsymbol{\lambda}$  för lämpligt valda  $\mathbf{B}$  och  $\boldsymbol{\lambda}$ . Ange  $\mathbf{B}$  och  $\boldsymbol{\lambda}$ . (Ledning:  $\boldsymbol{\lambda}$  har två element.) (3 p)

c) Nedan anges ett utdrag ur variansanalystabellen för försöket. Använd det för att testa nollhypotesen på nivån 5%.

Variationskälla	Kvs
Avvikelse från $H_0$	6.8910
Residual	1.1060
Totalt	7.9970

(4 p)

## Uppgift 3

Ett byggföretag utför en kvalitetskontroll genom att mäta fuktigheten i ett betongparti som består av ett antal olika betongblock. Man väljer ut ett stickprov på 5 block och genomför 3 mätningar på varje block. De uppmätta fuktigheterna  $Y_{i1}, Y_{i2}, Y_{i3}$  för block  $i = 1, \dots, 5$  antas följa en ensidig variansanalysmodell

$$Y_{ij} = \mu + \delta_i + \varepsilon_{ij}$$

av typ II, med väntevärde  $\mu$ , oberoende blockeffekter  $\delta_i \sim N(0, \sigma_\delta^2)$  och mätfel  $\varepsilon_{ij} \sim N(0, \sigma_\varepsilon^2)$ . Resultatet sammanfattas i följande tabell, i form av stickprovsmedelvärden  $\bar{Y}_i$  och stickprovsvarianser  $s_i^2$  för mätningarna inom respektive betongblock:

Block	$\bar{Y}_i$	$s_i^2$
1	3.1	0.035
2	2.6	0.031
3	2.8	0.020
4	3.3	0.046
5	2.7	0.023

a) Skatta de två varianskomponenterna  $\sigma_\delta^2$  och  $\sigma_\varepsilon^2$ . (Ledning: Du har nytta av att beräkna stickprovsvariansen av  $\bar{Y}_i$ ,  $i = 1, \dots, 5$ .) (5 p)

b) Ange ett 95% konfidensintervall för  $\mu$ . (Ledning: Den  $t$ -kvantil du behöver fås som kvadratroten ur en lämplig  $F$ -kvantil i tabellen nedan.) (5 p)

### Uppgift 4

Låt  $y_1, \dots, y_T$  vara observationer från en AR(1)-process

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + \varepsilon_t, \quad (2)$$

där  $\mu = E(Y_t)$  och  $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$  är oberoende och normalfördelade.

a) För vilka värden på  $\phi$  är processen stationär? (Inget bevis krävs.) (1 p)

b) Givet värden på  $\phi$  enligt a), härled värden på  $\sigma^2 = \text{Var}(Y_t)$  och autokorrelationsfunktionen  $\rho_k = \text{Corr}(Y_t, Y_{t+k})$  för  $k = 0, 1, 2, \dots$  (4 p)

c) Parametervektorn för en AR(1)-process kan skrivas  $\boldsymbol{\psi} = (\mu, \phi, \sigma_\varepsilon^2)$ . Låt  $f(y_t|y_{t-1})$  ange den betingade täthetsfunktionen för  $Y_t$  given  $Y_{t-1} = y_{t-1}$  och definiera en approximativ log likelihood

$$\begin{aligned} l(\boldsymbol{\psi}) &= \sum_{t=2}^T \log f(y_t|y_{t-1}) \\ &= -\sum_{t=2}^T \left[ \log(\sqrt{2\pi}\sigma_\varepsilon) + \frac{(y_t - \mu - \phi(y_{t-1} - \mu))^2}{2\sigma_\varepsilon^2} \right]. \end{aligned} \quad (3)$$

Bestäm ML-skattningarna  $\hat{\mu}$  och  $\hat{\phi}$  av  $\mu$  och  $\phi$ , baserat på den approximativa log likelihooden (3). (Ledning: Skriv om (2) som  $Y_t = \alpha + \phi Y_{t-1} + \varepsilon_t$ , där  $\alpha = \mu(1 - \phi)$ . Börja med att bestämma ML-skattningar  $\hat{\alpha}$  och  $\hat{\phi}$  av  $\alpha$  och  $\phi$ , som inte kommer att bero på värdet av  $\sigma_\varepsilon^2$ . Ditt svar kan uttryckas med hjälp av bland annat  $\bar{x} = \sum_{t=1}^{T-1} y_t / (T - 1)$  och  $\bar{y} = \sum_{t=2}^T y_t / (T - 1)$ .) (5 p)

### Uppgift 5

Anta att vi har en multipel linjär regressionsmodell

$$\mathbf{Y} = \mathbf{A}\boldsymbol{\theta} + \boldsymbol{\varepsilon}$$

med observationsvektor  $\mathbf{Y} = (Y_1, \dots, Y_N)^T$ , designmatris  $\mathbf{A}$ , regressionsparametrar  $\boldsymbol{\theta} = (\alpha, \beta_1, \dots, \beta_{k-1})^T$  och feltermsvektor  $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_N)$ , där  $\mathbf{I}_N$  är en identitetsmatris av ordning  $N$ . Minsta kvadrat-skattningen  $\hat{\boldsymbol{\mu}} =$

$(\hat{\mu}_1, \dots, \hat{\mu}_N)^T$  av väntevärdesvektorn  $\boldsymbol{\mu} = \mathbf{A}\boldsymbol{\theta}$  kan skrivas med hjälp av hattmatrisen  $\mathbf{H} = (h_{ij})_{i,j=1}^N$  som

$$\hat{\boldsymbol{\mu}} = \mathbf{H}\mathbf{Y}. \quad (4)$$

a) Utgå från minsta kvadrat-skattningen av  $\boldsymbol{\theta}$  och visa att hattmatrisen kan uttryckas endast med hjälp av designmatrisen enligt

$$\mathbf{H} = \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T. \quad (3 \text{ p})$$

b) Låt  $e_i = Y_i - \hat{\mu}_i$  vara residualen för observation  $i$ . Visa att

$$E(e_i^2) = \sigma^2(1 - h_{ii}). \quad (5)$$

(Ledning: Det kan vara enklast att först undersöka kovariansmatrisen  $\text{Var}(\mathbf{e}) = \text{Var}(\mathbf{Y} - \hat{\boldsymbol{\mu}})$  för hela residualvektorn  $\mathbf{e} = \mathbf{Y} - \hat{\boldsymbol{\mu}} = (e_1, \dots, e_N)^T$ , genom att utnyttja (4) och egenskaper hos  $\mathbf{H}$ .) (3 p)

c) Härled hattmatrisen för enkel linjär regression, där de förklarande variablerna före centrerings har värdena  $x_1, \dots, x_N$ . Använd sedan (5) för att först ge ett uttryck för  $E(e_i^2)$ , och sedan diskutera vilka observationspunkter  $(x_i, Y_i)$  som kan förväntas vara inflytelserika. (Ledning: Börja med att ställa upp designmatrisen. När du gör det får du enklast räkningar om du först centrerar de förklarande variablerna i regressionsmodellen.) (4 p)

	$f_1 = 1$	2	3	4	5	6	7	8	9	10
$f_2 = 1$	161.4	199.5	215.7	224.6	230.2	234.0	236.8	238.9	240.5	241.9
2	18.5	19.0	19.2	19.2	19.3	19.3	19.4	19.4	19.4	19.4
3	10.1	9.6	9.3	9.1	9.0	8.9	8.9	8.8	8.8	8.8
4	7.7	6.9	6.6	6.4	6.3	6.2	6.1	6.0	6.0	6.0
5	6.6	5.8	5.4	5.2	5.1	5.0	4.9	4.8	4.8	4.7
6	6.0	5.1	4.8	4.5	4.4	4.3	4.2	4.1	4.1	4.1
7	5.6	4.7	4.3	4.1	4.0	3.9	3.8	3.7	3.7	3.6
8	5.3	4.5	4.1	3.8	3.7	3.6	3.5	3.4	3.4	3.3
9	5.1	4.3	3.9	3.6	3.5	3.4	3.3	3.2	3.2	3.1
10	5.0	4.1	3.7	3.5	3.3	3.2	3.1	3.1	3.0	3.0
11	4.8	4.0	3.6	3.4	3.2	3.1	3.0	2.9	2.9	2.9
12	4.7	3.9	3.5	3.3	3.1	3.0	2.9	2.8	2.8	2.8
13	4.7	3.8	3.4	3.2	3.0	2.9	2.8	2.8	2.7	2.7
14	4.6	3.7	3.3	3.1	3.0	2.8	2.8	2.7	2.6	2.6
15	4.5	3.7	3.3	3.1	2.9	2.8	2.7	2.6	2.6	2.5
16	4.5	3.6	3.2	3.0	2.9	2.7	2.7	2.6	2.5	2.5
17	4.5	3.6	3.2	3.0	2.8	2.7	2.6	2.5	2.5	2.4
18	4.4	3.6	3.2	2.9	2.8	2.7	2.6	2.5	2.5	2.4
19	4.4	3.5	3.1	2.9	2.7	2.6	2.5	2.5	2.4	2.4
20	4.4	3.5	3.1	2.9	2.7	2.6	2.5	2.4	2.4	2.3
21	4.3	3.5	3.1	2.8	2.7	2.6	2.5	2.4	2.4	2.3
22	4.3	3.4	3.0	2.8	2.7	2.5	2.5	2.4	2.3	2.3
23	4.3	3.4	3.0	2.8	2.6	2.5	2.4	2.4	2.3	2.3
24	4.3	3.4	3.0	2.8	2.6	2.5	2.4	2.4	2.3	2.3
25	4.2	3.4	3.0	2.8	2.6	2.5	2.4	2.3	2.3	2.2
26	4.2	3.4	3.0	2.7	2.6	2.5	2.4	2.3	2.3	2.2
27	4.2	3.4	3.0	2.7	2.6	2.5	2.4	2.3	2.3	2.2
28	4.2	3.3	2.9	2.7	2.6	2.4	2.4	2.3	2.2	2.2
29	4.2	3.3	2.9	2.7	2.5	2.4	2.3	2.3	2.2	2.2
30	4.2	3.3	2.9	2.7	2.5	2.4	2.3	2.3	2.2	2.2

Table 1: F-kvantiler  $F_{0.05}(f_1, f_2)$  avrundade till en decimals noggrannhet