

# FORMELSAMMLING TIL STK2120

(Versjon av 12. mai 2010)

## 1 Enveis variansanalyse

Anta at  $Y_{ij} = \mu + \alpha_i + \epsilon_{ij}$ ;  $j = 1, 2, \dots, J_i$ ;  $i = 1, 2, \dots, I$ ; der  $\epsilon_{ij}$ -ene er uavhengige og  $N(0, \sigma^2)$ -fordelte. Da har vi at:

- (a) Den totale kvadratsummen  $SST = \sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{..})^2$  kan skrives som  $SST = SSE + SSTR$  der
- $SSE = \sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i.})^2$  er kvadratsummen for feil eller kvadratsummen innen ("within") grupper
- $SSTR = \sum_{i=1}^I J_i (\bar{Y}_{i.} - \bar{Y}_{..})^2$  er kvadratsummen for behandling eller kvadratsummen mellom ("between") grupper
- (b)  $SSE$  og  $SSTR$  er uavhengige
- (c)  $MSE = SSE / [\sum_{i=1}^I (J_i - 1)]$  er en forventningsrett estimator for  $\sigma^2$ .  
 $SSE / \sigma^2$  er kji-kvadratfordelt med  $\sum_{i=1}^I (J_i - 1)$  frihetsgrader.
- (d) Hvis alle  $\alpha_i$ -ene er lik null, er  $SSTR / \sigma^2$  kji-kvadratfordelt med  $I - 1$  frihetsgrader
- (e) Hvis  $J_i = J$  for  $i = 1, \dots, I$ , så er  
 $\max_{i_1, i_2} |(\bar{Y}_{i_1.} - \mu_{i_1}) - (\bar{Y}_{i_2.} - \mu_{i_2})| / \sqrt{MSE / J}$   
fordelt som den studentifiserte variasjonsbredde med parametere  $I$  og  $I(J - 1)$ .

## 2 Toveis variansanalyse

Anta at  $Y_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \epsilon_{ijk}$ ;  $k = 1, \dots, K$ ;  $j = 1, \dots, J$ ;  $i = 1, \dots, I$ ; der  $\epsilon_{ijk}$ -ene er uavhengige og  $N(0, \sigma^2)$ -fordelte. Da har vi at:

- (a) Den totale kvadratsummen  $SST = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (Y_{ijk} - \bar{Y}_{...})^2$  kan skrives som  $SST = SSA + SSB + SSAB + SSE$  der
- $SSA = JK \sum_{i=1}^I (\bar{Y}_{i..} - \bar{Y}_{...})^2$
- $SSB = IK \sum_{j=1}^J (\bar{Y}_{.j.} - \bar{Y}_{...})^2$
- $SSAB = K \sum_{i=1}^I \sum_{j=1}^J (\bar{Y}_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j.} + \bar{Y}_{...})^2$
- $SSE = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (Y_{ijk} - \bar{Y}_{ij.})^2$
- (b)  $SSA$ ,  $SSB$ ,  $SSAB$  og  $SSE$  er uavhengige
- (c)  $MSE = SSE / IJK(K - 1)$  er en forventningsrett estimator for  $\sigma^2$ .  
 $SSE / \sigma^2$  er kji-kvadratfordelt med  $IJK(K - 1)$  frihetsgrader.

- (d) Hvis alle  $\alpha_i$ -ene er lik null, er  $SSA/\sigma^2$  kji-kvadratfordelt med  $I - 1$  frihetsgrader
- (e) Hvis alle  $\beta_j$ -ene er lik null, er  $SSB/\sigma^2$  kji-kvadratfordelt med  $J - 1$  frihetsgrader
- (f) Hvis alle  $\gamma_{ij}$ -ene er lik null, er  $SSAB/\sigma^2$  kji-kvadratfordelt med  $(I - 1)(J - 1)$  frihetsgrader

### 3 Blokkforsøk (toveis variansanalyse uten gjentak)

Anta at  $Y_{ij} = \mu + \alpha_i + \beta_j + \epsilon_{ij}$ ;  $j = 1, \dots, J$ ;  $i = 1, \dots, I$ ; der  $\epsilon_{ij}$ -ene er uavhengige og  $N(0, \sigma^2)$ -fordelte. Da har vi at:

- (a) Den totale kvadratsummen  $SST = \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{..})^2$  kan skrives som  $SST = SSA + SSB + SSE$  der

$$SSA = J \sum_{i=1}^I (\bar{Y}_{i\cdot} - \bar{Y}_{..})^2$$

$$SSB = I \sum_{j=1}^J (\bar{Y}_{\cdot j} - \bar{Y}_{..})^2$$

$$SSE = \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{i\cdot} - \bar{Y}_{\cdot j} + \bar{Y}_{..})^2$$

- (b)  $SSA$ ,  $SSB$  og  $SSE$  er uavhengige

- (c)  $MSE = SSE/[(I - 1)(J - 1)]$  er en forventningsrett estimator for  $\sigma^2$ .  
 $SSE/\sigma^2$  er kji-kvadratfordelt med  $(I - 1)(J - 1)$  frihetsgrader.

- (d) Hvis alle  $\alpha_i$ -ene er lik null, er  $SSA/\sigma^2$  kji-kvadratfordelt med  $I - 1$  frihetsgrader

- (e) Hvis alle  $\beta_j$ -ene er lik null, er  $SSB/\sigma^2$  kji-kvadratfordelt med  $J - 1$  frihetsgrader

### 4 Tabelldata og kji-kvadrattester

- (a) Anta at  $(N_1, \dots, N_k)$  er multinomisk fordelt med sannsynligheter  $p_i$ , der  $\sum_{i=1}^k N_i = n$  og  $\sum_{i=1}^k p_i = 1$ .  
Hvis  $p_i = \pi_i(\boldsymbol{\theta})$ , der  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_m)$ , og  $\hat{\boldsymbol{\theta}}$  er maksimum likelihood estimatoren for  $\boldsymbol{\theta}$ , så er

$$\chi^2 = \sum_{i=1}^k \frac{(N_i - E_i)^2}{E_i}$$

tilnærmet kji-kvadratfordelt med  $k - 1 - m$  frihetsgrader når  $E_i = n\pi_i(\hat{\boldsymbol{\theta}}) \geq 5$  for (nesten) alle  $i$

- (b) Homogenitetstesting: Anta at for  $I = 1, \dots, I$  er  $(N_{i1}, \dots, N_{iJ})$  uavhengige og multinomisk fordelt med sannsynligheter  $p_{ij}$ , der  $\sum_{j=1}^J p_{ij} = 1$ .  
Hvis  $p_{1j} = \dots = p_{Ij}$ , så er

$$\chi^2 = \sum_{i=1}^I \sum_{j=1}^J \frac{(N_{ij} - E_{ij})^2}{E_{ij}}$$

tilnærmet kji-kvadratfordelt med  $(I - 1)(J - 1)$  frihetsgrader når  
 $E_{ij} = (N_i \cdot N_{\cdot j})/N_{..} \geq 5$  for (nesten) alle  $i, j$

- (c) Uavhengighetstesting: Anta at  $(N_{11}, \dots, N_{1J}, N_{21}, \dots, N_{2J}, \dots, N_{I1}, \dots, N_{IJ})$  er multinomisk fordelt med sannsynligheter  $p_{ij}$ , der  $\sum_{i=1}^I \sum_{j=1}^J p_{ij} = 1$ . Hvis  $p_{ij} = p_{i \cdot} p_{\cdot j}$  for alle  $i, j$ , så er

$$\chi^2 = \sum_{i=1}^I \sum_{j=1}^J \frac{(N_{ij} - E_{ij})^2}{E_{ij}}$$

tilnærmet kji-kvadratfordelt med  $(I - 1)(J - 1)$  frihetsgrader når  
 $E_{ij} = (N_i \cdot N_{\cdot j})/N_{..} \geq 5$  for (nesten) alle  $i, j$

## 5 Multippel lineær regresjon

Anta at  $Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + \epsilon_i ; i = 1, 2, \dots, n$ ; der  $x_{ij}$ -ene er kjente tall og  $\epsilon_i$ -ene er uavhengige og  $N(0, \sigma^2)$ -fordelte.

På matriseform kan vi skrive modellen som  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta}$ , der  $\mathbf{Y} = (Y_1, \dots, Y_n)^T$  og  $\boldsymbol{\beta} = (\beta_0, \dots, \beta_k)^T$  er henholdsvis  $n$ - og  $k + 1$ -dimensjonale vektorer, og  $\mathbf{X} = \{x_{ij}\}$  er en  $n \times (k + 1)$ -dimensjonal matrise. Vi har at:

- (a) Minste kvadraters estimator for  $\boldsymbol{\beta}$  er  $\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$ .
- (b) La  $\hat{\boldsymbol{\beta}} = (\hat{\beta}_0, \dots, \hat{\beta}_k)^T$ . Da er  $\hat{\beta}_j$ -ene normalfordelte og forventningsrette, og

$$\text{Var}(\hat{\beta}_i) = \sigma^2 c_{ii} \quad \text{og} \quad \text{Cov}(\hat{\beta}_i, \hat{\beta}_j) = \sigma^2 c_{ij}$$

der  $c_{ij}$  er element  $(i, j)$  i  $(k + 1) \times (k + 1)$  matrisen  $\mathbf{C} = (\mathbf{X}^T \mathbf{X})^{-1}$ .

- (c) La  $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik}$ , og sett  $SSE = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$ . Da er  $S^2 = SSE/(n - (k + 1))$  en forventningsrett estimator for  $\sigma^2$ , og  $(n - (k + 1))S^2/\sigma^2 \sim \chi^2_{n-(k+1)}$ . Videre er  $S^2$  og  $\hat{\boldsymbol{\beta}}$  uavhengige.
- (d) La  $S_{\hat{\beta}_i}^2$  være den varianseestimatoren for  $\hat{\beta}_i$  vi får ved å erstatte  $\sigma^2$  med  $S^2$  i formlen for  $\text{Var}(\hat{\beta}_i)$  i punkt b). Da er  $(\hat{\beta}_i - \beta_i)/S_{\hat{\beta}_i} \sim t_{n-(k+1)}$ .

## 6 Bootstrapping

Anta fordelingen til data  $\mathbf{X}$  er beskrevet ved en fordelingsfunksjon  $F$ . La  $\theta = \theta(F)$  være en egenskap ved  $F$  som estimeres ved  $\hat{\theta} = \hat{\theta}(\mathbf{X})$ .

- (a) Bootstrapping-idéen er å tilnærme egenskapene til  $\hat{\theta}$  ved å anta at et estimat  $\hat{F}$  på  $F$  er den sanne fordelingsfunksjonen.

(b) Bootstrap estimering av skjevhet til  $\hat{\theta}$ :

$$b_{\hat{\theta}} = \frac{1}{B} \sum_{b=1}^B \theta_b^* - \theta(\hat{F})$$

(c) Bootstrap estimering av standardavvik til  $\hat{\theta}$ :

$$\sqrt{\mathbb{E}^{\hat{F}}[(\hat{\theta}(\mathbf{X}^*) - \mathbb{E}^{\hat{F}}[\hat{\theta}(\mathbf{X}^*)])^2]}$$

(d) Standard bootstrap konfidensintervall:

$$(\hat{\theta} - \bar{\delta}, \hat{\theta} - \underline{\delta})$$

der  $\underline{\delta}$  og  $\bar{\delta}$  er nedre og øvre  $\alpha/2$  kvantil i bootstrap fordelingen til  $\Delta = \hat{\theta} - \theta$ .

## 7 Maksimum likelihood metoden

Anta at  $X_1, X_2, \dots, X_n$  har simultan punktsannsynlighet/sannsynlighetstetthet  $f(x_1, x_2, \dots, x_n | \boldsymbol{\theta})$ , der  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_p)$  er en parametervektor (skalar hvis  $p = 1$ ). Vi antar at  $f(x_1, x_2, \dots, x_n | \boldsymbol{\theta})$  tilfredsstiller visse deriverbarhetsbetingelser.

- (a) Gitt observerte verdier  $X_i = x_i; i = 1, \dots, n$ ; er likelihood-funksjonen  $\text{lik}(\boldsymbol{\theta}) = f(x_1, x_2, \dots, x_n | \boldsymbol{\theta})$  og loglikelihood-funksjonen  $l(\boldsymbol{\theta}) = \log(\text{lik}(\boldsymbol{\theta}))$ .
- (b) Maksimum likelihood *estimate*t er den verdien av  $\boldsymbol{\theta}$  som maksimerer  $\text{lik}(\boldsymbol{\theta})$  eller ekvivalent maksimerer  $l(\boldsymbol{\theta})$ . Hvis vi erstatter de observerte  $x_i$ -ene med de stokastiske  $X_i$ -ene, får vi maksimum likelihood *estimatoren*.
- (c) Maksimum likelihood estimatet  $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \dots, \hat{\theta}_p)$  er en løsning av ligningene  $s_j(\boldsymbol{\theta}) = 0; j = 1, \dots, p$ ; der  $s_j(\boldsymbol{\theta}) = (\partial/\partial\theta_j)l(\boldsymbol{\theta})$  er score-funksjonene. Vektoren av scorefunksjoner er  $\mathbf{s}(\boldsymbol{\theta}) = (s_1(\boldsymbol{\theta}), \dots, s_p(\boldsymbol{\theta}))^T$ .
- (d) Den observerte informasjonsmatrisen  $\bar{\mathbf{J}}(\boldsymbol{\theta})$  er  $p \times p$  matrisen med element  $(i, j)$  gitt ved  $\bar{J}_{ij}(\boldsymbol{\theta}) = -\frac{\partial^2}{\partial\theta_i\partial\theta_j}l(\boldsymbol{\theta})$ . Den forventede informasjonsmatrisen (eller Fishers informasjonsmatrise)  $\bar{\mathbf{I}}(\boldsymbol{\theta})$  er  $p \times p$  matrisen med element  $(i, j)$  gitt ved  $\bar{I}_{ij}(\boldsymbol{\theta}) = \mathbb{E}[\bar{J}_{ij}(\boldsymbol{\theta})]$ . For uavhengige og identisk fordelte observasjoner har vi at  $\bar{\mathbf{I}}(\boldsymbol{\theta}) = n\mathbf{I}(\boldsymbol{\theta})$  der  $\mathbf{I}(\boldsymbol{\theta})$  er forventet informasjon til en observasjon.
- (e) Når ligningene i punkt (c) ikke har en eksplisitt løsning, kan vi finne maksimum likelihood estimatet ved å bruke Newton-Raphsons metode:

$$\boldsymbol{\theta}^{(s+1)} = \boldsymbol{\theta}^{(s)} + \bar{\mathbf{J}}^{-1}(\boldsymbol{\theta}^{(s)})\mathbf{s}(\boldsymbol{\theta}^{(s)})$$

, ved å bruke Fishers scoringsalgoritme:

$$\boldsymbol{\theta}^{(s+1)} = \boldsymbol{\theta}^{(s)} + \bar{\mathbf{I}}^{-1}(\boldsymbol{\theta}^{(s)})\mathbf{s}(\boldsymbol{\theta}^{(s)}),$$

eller ved passende modifikasjoner av disse.

- (f) Når vi har “tilstrekkelig mye” data, er  $\hat{\theta}_i$  tilnærmet normalfordelt med forventning  $\theta_i$  og med varians lik det  $i$ -te diagonalelementet til  $\bar{\mathbf{I}}^{-1}(\boldsymbol{\theta})$ . Kovariansen mellom  $\hat{\theta}_i$  og  $\hat{\theta}_j$  er tilnærmet lik element  $(i, j)$  i  $\bar{\mathbf{I}}^{-1}(\boldsymbol{\theta})$ . Vi kan estimere varianser/kovarianser ved å sette inn  $\hat{\boldsymbol{\theta}}$  for  $\boldsymbol{\theta}$  i  $\bar{\mathbf{I}}^{-1}(\boldsymbol{\theta})$  eller i  $\bar{\mathbf{J}}^{-1}(\boldsymbol{\theta})$ .