

Oppsummering av STK2120

Geir Storvik

Vår 2011

Hovedtemaer

- ▶ Generelle inferensmetoder
- ▶ Spesielle modeller/metoder
- ▶ Bruk av R
 - ▶ Vil ikke bli testet på kommandoer, men må forstå generelle utskrifter

Generelle inferensmetoder

- ▶ Estimering
 - ▶ Maksimum likelihood
- ▶ Konfidensintervaller
 - ▶ Normaltilnærming
 - ▶ Bootstrapping
- ▶ Hypotesetesting
 - ▶ Likelihood ratio test
- ▶ Grunnlag: Sannsynlighetsregning

Spesielle modeller/metoder

- ▶ Variansanalyse
- ▶ Regresjon
 - ▶ Lineær
 - ▶ Ikke-lineær
 - ▶ Logistisk
- ▶ Kategoriske data/føyningstest
- ▶ Sjekk av modell-antagelser
 - ▶ Transformasjoner

Maksimum likelihood/Sannsynlighetsmaksimering

- ▶ $y_1, \dots, y_n \stackrel{uif}{\sim} f(y; \theta)$
- ▶ $L(\theta; \mathbf{y}) = f(y_1, \dots, y_n; \theta) = \prod_i f(y_i; \theta)$
- ▶ $\log L(\theta; \mathbf{y}) = \sum_i \log f(y_i; \theta)$
- ▶ $\hat{\theta} = \operatorname{argmax}_{\theta} L(\theta; \mathbf{y})$
 - ▶ Konsistent, asymptotisk effisient
 - ▶ Analyttiske løsninger for lineære/Gaussiske modeller
Ett-/to- utvalgs modeller, variansanalyse, lineær regresjon
 - ▶ Generelt: Numerisk optimering
- ▶ For stor n :

$$\hat{\theta} \approx N(\theta, I(\hat{\theta})^{-1}) \approx N(\theta, J(\hat{\theta}; \mathbf{y})^{-1})$$

$$J(\theta; \mathbf{y}) = - \frac{\partial^2}{\partial \theta \partial \theta^T} \log L(\theta; \mathbf{y})$$

$$I(\theta) = E[J(\theta; \mathbf{y})] \quad \text{Alltid pos. (semi)definit}$$

Konfidensintervaller

- ▶ Normaltilnærmning: $\hat{\theta}_j \pm z_{\alpha/2} \text{SE}(\hat{\theta}_j)$.
 - ▶ $\text{SE}(\hat{\theta}_j)$: Normaltilnærmning ($\sqrt{I(\theta)_{jj}}$) eller bootstrapping
- ▶ Bootstrap intervaller: $\hat{\theta}_{j,1}^*, \dots, \hat{\theta}_{j,B}^*$ bootstrap simuleringer
 - ▶ Normaltilnærmning: $\text{SE}(\hat{\theta}_j) = \sqrt{\frac{1}{B} \sum_{b=1}^B (\hat{\theta}_{j,b}^* - \bar{\hat{\theta}}^*)^2}$
 - ▶ Standard bootstrap intervaller: $(\hat{\theta}_j - \delta_U, \hat{\theta}_j - \delta_L)$

$$\hat{\delta}_L = \hat{\theta}_{j,(k_1)}^* = k_1 \text{ minste } \hat{\theta}_{j,b}^*$$

$$\hat{\delta}_U = \hat{\theta}_{j,(k_2)}^* = k_2 \text{ minste } \hat{\theta}_{j,b}^*$$

$$k_1 = B * \alpha/2, k_2 = B * (1 - \alpha/2)$$

Numerisk optimering

- ▶ Sentrale begreper

- ▶ Likelihood $L(\theta; \mathbf{y}) = f(\mathbf{y}; \theta)$
- ▶ Skår funksjonen $s(\theta; \mathbf{y}) = \frac{\partial}{\partial \theta} \log L(\theta; \mathbf{y})$
- ▶ Observert informasjon $J(\theta; \mathbf{y}) = -\frac{\partial}{\partial \theta \theta^T} \log L(\theta; \mathbf{y})$
- ▶ Forventet (Fisher) informasjon $I(\theta) = E[J(\theta; \mathbf{y})]$

- ▶ Newton-Raphson

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

- ▶ Scoring: $J(\boldsymbol{\theta}^s; \mathbf{x}) \rightarrow I(\boldsymbol{\theta}^s)$.
- ▶ Mindre hopp
- ▶ Reparametrisering
- ▶ Dimensjonsreduksjon

Bootstrapping

- ▶ Av interesse: Egenskaper til $\hat{\theta} = \hat{\theta}(\mathbf{y})$ ved gjentatt bruk av denne
- ▶ Bootstrap idé: Simuler $\hat{\theta}^* = \hat{\theta}(\mathbf{y}^*)$ der $\mathbf{y}^* = (y_1^*, \dots, y_n^*)$ er bootstrap simuleringer av \mathbf{y} .
- ▶ Ikke-parametrisk bootstrapping: Trekk y_1^*, \dots, y_n^* med tilbakelegging fra $\{y_1, \dots, y_n\}$.
- ▶ Parametrisk bootstrapping: Anta $y_i \sim f(y; \theta)$. Simuler $y_i^* \sim f(y; \hat{\theta})$
- ▶ Semi-parametrisk bootstrapping: Mellomting
Eksempel: Regresjon

$$y_i = g(x_i; \beta) + \varepsilon_i$$

$$y_i^* = g(x_i; \hat{\beta}) + \varepsilon_i^*$$

ε_i^* trelles med tilbakelegging fra $\{\hat{\varepsilon}_1, \dots, \hat{\varepsilon}_n\}$, $\hat{\varepsilon}_i = y_i - g(x_i; \hat{\beta})$.

- ▶ Forventningsskjevhet, usikkerhet, konfidensintervaller
- ▶ Egenskaper: STK4170

Hypotesetesting

Antar data $y_1, \dots, y_n \stackrel{uif}{\sim} f(y; \theta)$

Ønsker å teste $H_0 : \theta \in \Omega_0$ mot $H_a : \theta \in \Omega_a$

Prosedyre

- ▶ Spesifiser en test-observator
- ▶ Bestem et forkastningsområde for gitt signifikansnivå
- ▶ Beregn test-observator og forkastningsområde numerisk og konkluder
 - ▶ Hvis test-observator i forkastningsområde, forkast H_0 på det gitte signifikansnivå
 - ▶ Ellers, konkluder med at det ikke er grunnlag i data for å forkaste H_0 på det gitte signifikansnivå.
- ▶ Merk: Dette er *ikke* det samme som å påstå at H_0 er riktig!
- ▶ Ofte vanlig å rapportere P-verdi som angir hvor mye bevis det ligger i data.
- ▶ Merk: Bør skille mellom *statistisk signifikant* og *praktisk signifikant*
Ved mye data kan en ende opp med å forkaste $H_0 : \theta = \theta_0$ selv om $\hat{\theta}$ er svært lik θ_0 .

Likelihood ratio test

Antar data $y_1, \dots, y_n \stackrel{uif}{\sim} f(y; \theta)$

Ønsker å teste $H_0 : \theta \in \Omega_0$ mot $H_a : \theta \in \Omega_a$

- ▶ Neyman-Pearson: $H_0 : \theta = \theta_0$ mot $H_a : \theta = \theta_a$

$$LR = \frac{L(\theta_0; \mathbf{y})}{L(\theta_a; \mathbf{y})}$$

optimal testobsevator

- ▶ Generell likelihood ratio

$$LR = \frac{\max_{\theta \in \Omega_0} L(\theta; \mathbf{y})}{\max_{\theta \in \Omega} L(\theta; \mathbf{y})}, \quad \Omega = \Omega_0 \cup \Omega_a$$

- ▶ $-2 \log LR \stackrel{H_0}{\approx} \chi^2_{df}$, $df = |\Omega| - |\Omega_0|$
- ▶ P-verdi: $\Pr(\chi^2_{df} > -2 \log LR)$
- ▶ Ofte: LR må beregnes numerisk.

Variansanalyse

- ▶ Enveis variansanalyse

$$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij} \quad \sum_i \alpha_i = 0$$

$$\blacktriangleright H_0 : \alpha_i = 0, \quad F = \frac{SSTr/(I-1)}{SSE/I(J-1)}$$

- ▶ Testing av mange hypoteser
 - ▶ Tukey's metode

$$H_0 : \alpha_i = \alpha_j, |\bar{y}_{i\cdot} - \bar{y}_{j\cdot}| > Q_{\alpha, I, I(J-1)} \sqrt{MSE/J}$$

- ▶ Toveis variansanalyse

$$Y_{ijk} = \mu + \alpha_i + \beta_j + \delta_{ij} + \varepsilon_{ijk}$$

$$H_0 : \alpha_i = 0 \quad F = \frac{SSA/(I-1)}{SSE/IJ(K-1)}$$

$$H_0 : \beta_j = 0 \quad F = \frac{SSB/(J-1)}{SSE/IJ(K-1)}$$

$$H_0 : \delta_{ij} = 0 \quad F = \frac{SSAB/(I-1)(J-1)}{SSE/IJ(K-1)}$$

Lineær regresjon

- ▶ Modell $Y_i = \beta_0 + \sum_{j=1}^k \beta_j x_{ij} + \varepsilon_i$
- ▶ Antagelser
 - ▶ $E[\varepsilon_i] = 0$
 - ▶ $Var[\varepsilon_i] = \sigma^2$
 - ▶ Uavhengighet
 - ▶ Normalfordelte
- ▶ Estimering
 - ▶ $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$
 - ▶ Forventningsrett
 - ▶ $\text{COV}(\hat{\beta}) = \sigma^2 [\mathbf{X}^T \mathbf{X}]^{-1}$
 - ▶ $\hat{\sigma}^2 = \frac{1}{n-k-1} \sum_i (y_i - \hat{y}_i)^2$
 - ▶ $\hat{\mathbf{y}} = \mathbf{H}\mathbf{y}, \mathbf{H} = \mathbf{X}[\mathbf{X}^T \mathbf{X}]^{-1} \mathbf{X}^T$
 - ▶ Projeksjon ned i plan spent ut av x -ene.
- ▶ Konfidensintervaller
 - ▶ $\hat{\beta}_j \pm t_{\alpha/2; n-k-1} s_{\hat{\beta}_j}$

Ikke-lineær regresjon

- ▶ $Y_i = g(\mathbf{x}_i; \boldsymbol{\beta}) + \varepsilon_i$
- ▶ Vanlige antagelser på $\{\varepsilon_i\}$.
- ▶ Numerisk optimering for å finne ML-estimater
- ▶ Egenskaper/konfidensintervall ved normaltilnærming eller bootstrapping

Logistisk regresjon

- ▶ Respons $Y_i \in \{0, 1\}$.
- ▶ $Y_i \sim \text{Binom}(1, p(x_i))$

$$p(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}$$

- ▶ Numerisk optimering for å finne ML-estimater
- ▶ Egenskaper/konfidensintervall ved normaltilnærming (eller bootstrapping)
- ▶ Eksempel på *Generaliserte lineære modeller*, tema i STK3100.

Analyse av kategoriske data

- ▶ Gruppering av data i kategorier, data er antall innen hver kategori
- ▶ Sentral fordeling: Multinomisk fordeling
- ▶ Enveis gruppering
- ▶ Toveis gruppering
 - ▶ Test av homogenitet
 - ▶ Test av uavhengighet

En-veis gruppering

- ▶ En populasjon, utvalg på n , N_i antall i kategori i
- ▶ Antar $(N_1, \dots, N_k) \sim \text{Multinom}(n, p_1, \dots, p_k)$
- ▶ $H_0 : p_i = p_{i0}, i = 1, \dots, k$

$$\chi^2 = \sum_{i=1}^k \frac{(n_i - np_{i0})^2}{np_{i0}} \stackrel{H_0}{\approx} \chi^2_{k-1}$$

- ▶ $H_0 : p_i = \pi_i(\theta), i = 1, \dots, k$

$$\chi^2 = \sum_{i=1}^k \frac{(n_i - n\pi_i(\hat{\theta}))^2}{n\pi_i(\hat{\theta})} \stackrel{H_0}{\approx} \chi^2_{k-1-m}$$

- ▶ $\hat{\theta}$ er ML-estimat.
- ▶ Kan brukes til testing av fordelingsantagelser

To-veis gruppering

- ▶ Testing av homogenitet
 - ▶ I populasjoner, utvalg n_i fra populasjon i , n_{ij} fra kateg. j
 - ▶ $(N_{i1}, \dots, N_{iJ}) \sim \text{Multinom}(n_i; p_{i1}, \dots, p_{iJ})$, $i = 1, \dots, I$.
 - ▶ $H_0 : p_{ij} = p_j$
 - ▶ Pearson's χ^2 test, $df = (I - 1) * (J - 1)$
- ▶ Testing av uavhengighet
 - ▶ 1 populasjon, utvalg n , n_{ij} fra kateg. (i, j)
 - ▶ $(N_{11}, \dots, N_{ij}, \dots, N_{IJ}) \sim \text{Multinom}(n; p_{11}, \dots, p_{ij}, \dots, p_{IJ})$.
 - ▶ $H_0 : p_{ij} = p_{i\cdot} * p_{\cdot j}$
 - ▶ Pearson's χ^2 test, $df = (I - 1) * (J - 1)$

Veien videre

- ▶ STK2120 dekker de *generelle* prinsipper.
- ▶ Kan takle mange ulike situasjoner (også mange vi ikke har diskutert!)
- ▶ Mange aspekter som krever mer.
- ▶ Illustrasjon relasjon lengde fisk og alder

Fiske data

- ▶ Oblig: $\{(l_i, a_i), i = 1, \dots, n\}$
- ▶ I praksis $\{(l_{b,i}, a_{b,i}, x_b), b = 1, \dots, B, i = 1, \dots, n_b\}$, b båt.
- ▶ Av interesse: $E[l_{b,i} | a_{b,i}, x_b]$, $Pr(A_{b,i} = a | x_b)$.
- ▶ Regresjonsmodeller for multinomiske data, tema i STK3100

$$\Pr(A_{b,i} = a) = \frac{\exp(\alpha_{a,0} + \alpha_{a,1}x_b)}{\sum_{a'} \exp(\alpha_{a',0} + \alpha_{a',1}x_b)}$$

- ▶ Fisk fra samme båt likere enn fisk fra forskjellige båter.
- ▶ Mulig modell:

$$l_{b,i} = \beta_0 + \eta_b + \beta_1 \log(a_{b,i}) + \varepsilon_{b,i}$$

der $\eta_b \sim N(0, \sigma_\eta^2)$.

- ▶ η_b er en *tilfeldig effekt* som modellerer *korrelasjoner innen båter*
Tema i STK3100
- ▶ Også aktuelt å modellere korrelasjoner i fordeling for alder
Tema i STK3100
- ▶ Tidsstrukturer når data er samlet inn over flere år:
STK3100/4060/4110

Fiske data

$$I_{b,i} = \beta_0 + \eta_b + \beta_1 \log(a_{b,i}) + \varepsilon_{b,i}$$

- ▶ Ofte: Alder mangler, men lengde kan gi informasjon om alder
Missing data: Simuleringstilnærming STK4050, andre tilnærninger i andre kurs.
- ▶ Romlig struktur: Båter som fisker i nærheten av hverandre vil ha likere lengde/alder
Bygger inn korrelasjoner mellom η_b -ene.
Romlig statistikk: STK4150
- ▶ Mange mulige modeller, hvordan velge mellom disse? STK4160
Bootstrapping i kompliserte situasjoner: STK4170
- ▶ Vet mye om hvordan fisk vokser fra tidligere studier, dvs har gode gjett på β_0, β_1 .
Apriori informasjon: Bayesiansk statistikk, STK4020
- ▶ Kompliserte beregninger: Monte Carlo metoder STK4050