

UNIVERSITETET I OSLO

Det matematisk-naturvitenskapelige fakultet

Eksamen i:	STK1110 — Statistiske metoder og dataanalyse 1.
Eksamensdag:	Onsdag 5. desember 2007.
Tid for eksamen:	9.00 – 12.00.
Oppgavesettet er på	4 sider.
Vedlegg:	Tabell for t -fordelingen.
Tillatte hjelpemidler:	Godkjent lommeregner og Formelsamling for STK1100 og STK1110.

Kontroller at oppgavesettet er komplett før du begynner å besvare spørsmålene.

Oppgave 1.

I USA er Thanksgiving Day, som feires den fjerde torsdagen i november, en nasjonal høytidsdag. På denne dagen spises det tradisjonelt kalkun som festmat. Tabell 1 gir vekten (i pund) for tilfeldig valgte Thanksgiving-kalkuner fra to delstater i USA.

Tabell 1: Slaktevekt for kalkuner fra to delstater i USA.

Delstat	Virginia	Wisconsin
Vekt (i pund)	13.1	11.5
	12.4	14.2
	13.2	15.4
	11.8	13.1
		13.8
Gjennomsnitt	12.625	13.600
Empirisk standardavvik	0.655	1.440

Vi lar μ_1 være forventet vekt for en tilfeldig valgt kalkun fra Virginia, mens μ_2 er forventet vekt for en tilfeldig valgt kalkun fra Wisconsin.

(Fortsettes side 2.)

- Bestem et 90% konfidensintervall for $\mu_2 - \mu_1$ og diskuter hva intervallet sier deg. Beskriv hvilke forutsetninger konfidensintervallet bygger på.
- Angi en test med signifikansnivå 5% for nullhypotesen $H_0 : \mu_1 = \mu_2$ mot den alternative hypotesen $H_1 : \mu_1 \neq \mu_2$. Hva blir konklusjonen av testen?
- Forklar hva vi mener med P -verdien til en test. Bestem (så godt du kan) P -verdien for testen i punkt b.

Oppgave 2.

Thanksgiving-kalkunene i oppgave 1 var ikke like gamle da de ble slaktet. Tabell 2 viser kalkunenes alder (i uker) ved slakting. For oversiktens skyld gir vi også slaktevektene i tabellen.

Tabell 2: Slaktevekt og slaktealder for kalkuner.

Virginia		Wisconsin	
Alder	Vekt	Alder	Vekt
29	13.1	21	11.5
27	12.4	27	14.2
28	13.2	29	15.4
26	11.8	23	13.1
		25	13.8

- Plott vekten av kalkunene mot alderen ved slakting. Utfør plottingen i ett diagram, men benytt forskjellige symboler for de to delstatene. Kommenter plottet.

For å studere hvilken betydning delstat og alder har for slaktevekten til kalkunene, setter vi opp regresjonsmodellen

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + e_i. \quad (1)$$

I modellen (1) er:

- Y_i slaktevekten til kalkun nummer i (fra begge delstatene sett under ett),
- x_{i1} alderen ved slakting til kalkun nummer i ,
- $x_{i2} = 1$ hvis kalkun nummer i er fra Wisconsin, $x_{i2} = 0$ hvis kalkun nummer i er fra Virginia.

(Fortsettes side 3.)

- b) Gi en fortolkning av parametrene β_1 og β_2 i regresjonsmodellen (1), og beskriv hvilke forutsetninger regresjonsmodellen bygger på. Syns du modellformuleringen (1) virker rimelig i lys av plottet i punkt a)?

Ut fra tallene i tabell 2 finner vi at minste kvadraters estimater er $\hat{\beta}_0 = 0.311$, $\hat{\beta}_1 = 0.448$ og $\hat{\beta}_2 = 2.094$, og at estimert standardfeil til $\hat{\beta}_2$ er $S_{\hat{\beta}_2} = 0.235$. (Du skal *ikke* vise dette.)

- c) Angi en test med signifikansnivå 5% for nullhypotesen $H_0 : \beta_2 = 0$ mot den alternative hypotesen $H_1 : \beta_2 \neq 0$. Hva blir konklusjonen av testen? Kommenter resultatet i lys av testen i punkt b i oppgave 1.

Ut fra tallene i tabell 2 har vi at residualkvadratsummen er

$$RSS = \sum_{i=1}^9 \left(Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} \right)^2 = 0.5648.$$

Vi innfører 9×3 matrisen

$$\mathbf{X} = \begin{pmatrix} 1 & 29 & 0 \\ 1 & 27 & 0 \\ 1 & 28 & 0 \\ 1 & 26 & 0 \\ 1 & 21 & 1 \\ 1 & 27 & 1 \\ 1 & 29 & 1 \\ 1 & 23 & 1 \\ 1 & 25 & 1 \end{pmatrix}$$

Da er

$$(\mathbf{X}^T \mathbf{X})^{-1} = \begin{pmatrix} 17.06 & -0.611 & -1.778 \\ -0.611 & 0.0222 & 0.0556 \\ -1.778 & 0.0556 & 0.589 \end{pmatrix}$$

- d) Finn den estimerte standardfeilen $S_{\hat{\beta}_1}$ til $\hat{\beta}_1$ og bestem et 95% konfidensintervall for β_1 . Forklar hva intervallet sier deg.

Oppgave 3.

En bedrift produserer lysstoffrør. Levetiden (i timer) av et tilfeldig valgt lysstoffrør antas å være en stokastisk variabel med sannsynlighetstetthet

$$f(y|\theta) = \begin{cases} \frac{y}{\theta} e^{-y^2/2\theta} & \text{for } y > 0 \\ 0 & \text{ellers} \end{cases} \quad (2)$$

der $\theta > 0$.

(Fortsettes side 4.)

- a) La $F(y|\theta)$ være den kumulative fordelingsfunksjonen som svarer til sannsynlighetstettheten (2). Medianen $y_{0.50}$ er gitt ved at $F(y_{0.50}|\theta) = 0.50$. Vis at $y_{0.50} = \sqrt{2\theta \log 2}$. (Her står "log" for den naturlige logaritmen.)

Bedriften ønsker å studere levetiden til lysstoffrørene. For å gjøre det, observerer de levetidene Y_1, Y_2, \dots, Y_{20} for 20 tilfeldig valgte lysstoffrør. Vi antar at Y_1, Y_2, \dots, Y_{20} er uavhengige og identisk fordelte med sannsynlighetstetthet gitt ved (2).

- b) Vis at maksimum likelihood estimatoren $\hat{\theta}$ er gitt ved $\hat{\theta} = \frac{1}{40} \sum_{i=1}^{20} Y_i^2$.
- c) Bedriften ønsker å teste nullhypotesen at median levetid er høyst 1000 timer mot alternativet at den er mer enn 1000 timer. Vis at det er det samme som å teste

$$H_0 : \theta \leq \theta_0 \quad \text{mot} \quad H_1 : \theta > \theta_0$$

der $\theta_0 = 10^6 / (2 \log 2)$.

- d) En rimelig test forkaster H_0 hvis $\hat{\theta} > k$. Bestem k slik at testen får signifikansnivå 5%. (*Vink:* En kan vise at $\frac{1}{\theta} \sum_{i=1}^{20} Y_i^2$ er kji-kvadratfordelt med 40 frihetsgrader. Du kan bruke dette resultatet uten å vise det. Utvalgte fraktiler i kji-kvadratfordelingen med 40 frihetsgrader er gitt i tabell 3 nedenfor.)
- e) Bestem (så godt du kan) styrken for testen i punkt d hvis median levetid er 1250 timer. Hva blir da sannsynligheten for feil av type II?

Tabell 3: Fraktiler for kji-kvadratfordelingen med 40 frihetsgrader.

p	0.025	0.05	0.10	0.20	0.30	0.40	0.50
χ_p^2	24.43	26.51	29.05	32.34	34.87	37.13	39.33
p	0.60	0.70	0.80	0.90	0.95	0.975	
χ_p^2	41.62	44.16	47.27	51.81	55.76	59.34	

SLUTT