

Bokmål tekst
 Faglig kontakt under eksamen:
 John Tyssedal, telefon 73593534

Eksamen i fag SIF 5066 Anvendt statistikk

Mandag 28. mai 2001
 Tid: 09.00-13.00

Hjelpemidler: Godkjent lommekalkulator
 Tapir: Formler og tabeller i statistikk/Statistiske tabeller og formler
 Et gult ark med egne notatar.

Sensuren faller i uke 25.

Oppgave 1.

En bedrift har problemer med sprekkdannelser i produksjonen av stålfjærer. I en testperiode på 20 dager testet de daglig de 200 først produserte fjærene og prosentvis antall fjærer uten sprekkdannelser ble notert.

65 65 70 75 68 72 66 66 73 77 71 70 64 69 72 73 66 68 73 77

Gjennomsnittet av disse 20 tallene er 70.

- a) La X_i , være antall fjærer med sprekkdannelser på dag i , $i = 1, 2, \dots, 20$. Under hvilke forutsetninger vil hver X_i , $i = 1, 2, \dots, 20$, være binomisk fordelt. Konstruer så et kontrollkort for denne produksjonsprosessen basert på dataene ovenfor. Plott inn de 10 siste observasjonene. Ser prosessen ut til å være i kontroll?

I resten av oppgaven kan de anta at daglig testing av 200 fjærer ligger til grunn for rapporteringen.

Bedriften syntes at tallet på fjærer uten sprekkdannelser var for lavt. De hadde sterk mistanke om at temperaturen på oljen som de brukte til å kjøle ned fjærene kunne ha noe å si for sprekkdannelsene. Det ble derfor satt i gang forsøk for å undersøke dette. I 4 dager gikk produksjonen med en kjøletemperatur på 20°C og i 4 dager med en

kjøletemperatur på 50°C. Prosentvis antall fjærer uten sprekkdannelse for de to tilfellene er gitt nedenfor.

20°C	68 72 73 67
50°C	74 68 73 69

b) Hvorfor er det naturlig å anta at dataene ovenfor kan tilnærmes med en normalfordeling?

De vil undersøke om det er forskjell i sprekkdannelse ved de to temperaturene. Utskrift fra en analyse med MINITAB er gitt nedenfor.

Two Sample T-Test and Confidence Interval

Two sample T for sprekk20 vs sprekk50

	N	Mean	StDev	SE Mean
sprekk20	4	70.00	2.94	1.5
sprekk50	4	71.25	3.30	1.7

95% CI for μ sprekk20 - μ sprekk50: (-6.7, 4.2)

T-Test μ sprekk20 = μ sprekk50 (vs not =): T = -0.56 P = 0.59 DF = 6

Both use Pooled StDev = 3.13

Formuler hypotesetesten. Hvilke forutsetninger om dataene bygger en slik test på? Sett opp uttrykket for testobservator. Hva blir konklusjonen når signifikansnivået er 5%? Grunngi svaret.

Det ble hevdet at andre faktorer som temperaturen i stålet og tilsetning av karbon også kunne påvirke sprekkdannelse. De bestemte seg derfor for å utføre et flerfaktor forsøk. Siden flere mente at temperaturen i kjøleoljen måtte ha noe å si, ble også denne faktoren tatt med. De tre faktorene med valgte nivåer er gitt nedenfor.

	-	+
A: Stål temperatur	780°C	880°C
B: Tilsetning av karbon	0.5%	0.7%
C: Olje temperatur	20°C	50°C

Det ble bestemt at en først skulle gjøre de 4 enkeltforsøkene nedenfor. Responsen er fortsatt målt i prosentvis stålfjærer uten sprekkdannelse.

A	B	C	% sprekkfrie fjærer
-1	-1	1	59
1	-1	-1	79
-1	1	-1	61
1	1	1	87

- c) Hva slags forsøk er dette? Hva blir definerende relasjon for dette forsøket? Finn ut hvordan effektene er konfunderte og regn ut estimatet for de 3 effektene.

De bestemte så å utvide forsøket med de 4 enkeltforsøkene nedenfor.

A	B	C	% sprekkfrie fjærer
-1	-1	-1	67
1	-1	1	90
-1	1	1	52
1	1	-1	75

- d) Resultatet fra analysen av disse 4 enkeltforsøkene ble:

Term	Effect	Coef
Constant		71.000
A	23.000	11.500
B	-15.000	-7.500
C	-0.000	-0.000

Bruk dette til å finne estimater for hovedeffektene av faktorene A, B og C og samspillet mellom faktorene A og C basert på alle de 8 forsøkene.

For bedre å kunne vurdere hvilke effekter som er signifikante bestemte de seg for å gjøre et gjentak av forsøket. Det nye forsøket ble gjort etter det samme oppsettet som det første, det vil si som to fraksjonerte forsøk hver bestående av 4 enkeltforsøk og der samme generator (definerende kontrast) ligger til grunn for fraksjoneringen. Således ble hele forsøket egentlig utført i 4 blokker hver på 4 enkeltforsøk. Deler av en analyse med MINITAB er gitt nedenfor.

Fractional Factorial Fit

Estimated Effects and Coefficients for %sprekkfrie (coded units)

Term	Effect	Coef
Constant		70.875
Block 1		0.125
2		0.625
3		-1.375
A	22.250	11.125
B	-6.000	-3.000
C	2.500	1.250
A*B	1.000	0.500
A*C	11.000	5.500
B*C	-1.750	-0.875

Analysis of Variance for C5 (coded units)

Source	DF	Seq SS	Adj MS	F	P
Blocks	3	10.75	3.583	0.78	0.546
Main Effects	3	2149.25	716.417	156.31	0.000
2-Way Interactions	3	500.25	166.750	36.38	0.000
Residual Error	6	27.50	4.583		
Total	15	2687.75			

e) Finn variansen til effektene uttrykt ved variansen til enkeltobservasjonene og finn ut hvilke effekter som er signifikante på 5% nivå. Tolk resultatet av estimeringen.

Analysen av forsøket ovenfor kan også gjøres med vanlig regresjonsanalyse. Ved innlesing av dataene ble verdiene for respons og faktorer analysert i 1d) lagt først, deretter verdiene analysert i 1c) og så verdiene i gjentak etter samme mønster. For å trekke ut variasjonen forårsaket av eventuelle blokkeffekter ble det i designmatrisen lagt til 3 nye forklaringsvariabler, B12, B13 og B14 med kolonneverdier som gitt nedenfor.

$$B12 = (0000111100000000)'$$

$$B13 = (0000000011110000)'$$

$$B14 = (00000000000001111)'$$

Analysen med MINTAB gav som resultat:

Regression Analysis

The regression equation is

$$\text{msprekkfri} = 71.0 + 11.1 A - 3.00 B + 1.25 C + 0.500 A*B + 5.50 A*C - 0.875 B*C + 0.50 B12 - 1.50 B13 + 0.50 B14$$

Predictor	Coef	StDev	T	P
Constant	71.000	1.070	66.33	0.000
A	11.1250	0.5352	20.79	0.000
B	-3.0000	0.5352	-5.61	0.001
C	1.2500	0.5352	2.34	0.058
A*B	0.5000	0.5352	0.93	0.386
A*C	5.5000	0.5352	10.28	0.000
B*C	-0.8750	0.5352	-1.63	0.153
B12	0.500	1.514	0.33	0.752
B13	-1.500	1.514	-0.99	0.360
B14	0.500	1.514	0.33	0.752

S = 2.141

R-Sq = 99.0%

R-Sq(adj) = 97.4%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	9	2660.25	295.58	64.49	0.000
Residual Error	6	27.50	4.58		
Total	15	2687.75			

Source	DF	Seq SS
A	1	1980.25
B	1	144.00
C	1	25.00
A*B	1	4.00
A*C	1	484.00
B*C	1	12.25
B12	1	2.08
B13	1	8.17
B14	1	0.50

- f) Forklar utifra utskriften hvorfor gjennomsnittet av responsverdiene i de 4 blokkene er 71.0, 71.5, 69.5 og 71.5. Bruk dette til å rekne ut kvadratsummen for blokker og test om en modell som kun består av et konstantledd, de tre hovedeffektene av A, B og C og tofaktorsamspillene mellom disse faktorene forklarer en signifikant del av variasjonen i dataene. (Det er tenkt at de skal la variasjonen mellom blokker inngå i feilen.) Hva blir R^2 for en slik modell?
- g) De bestemmer seg for å se bort fra blokkeffekten, og vil tilpasse en modell der kun konstantleddet, hovedeffekten av A og B og samspillet AC inngår. Hva blir den tilpassete modellen? Hva blir R^2 for denne modellen? Konstruer et 95% prediksjonsintervall for prosentvis antall stålfjærer uten sprekkdannelser når faktorene A og C er på høyt nivå (+) og faktor B er på lavt nivå (-) basert på denne modellen.

Oppgave 2

Fire tilfeldig valgte laboratorier som vi skal kalle A, B, C og D, ble plukket ut til å være med i et forsøk for å teste kvaliteten av en bestemt type ost. Målet med forsøket var å detektere kilder til variasjon i kvalitetsrapporteringen av osten, spesielt om variasjonen mellom laboratorier er et problem. En ost ble delt opp i 4 biter og hvert laboratorium får tilsendt en ostebit og bedt om å levere 5 kvalitetsvurderinger av denne. Resultatet av forsøket er synt i tabellen nedenfor.

A	B	C	D
16.0	17.0	16.9	15.0
17.1	17.3	16.1	15.9
16.9	16.2	16.4	16.0
17.2	17.1	16.1	15.9
17.0	16.0	16.6	16.2

En analyse med MINITAB gav følgende utskrift.

General Linear Model

Factor	Type	Levels	Values
Lab	random	4	1 2 3 4

Analysis of Variance for C1, using Adjusted SS for Tests

Source	DF	Seq SS	Adj SS	Adj MS	F	P
Lab	3	3.2415	3.2415	1.0805	4.79	0.014
Error	16	3.6080	3.6080	0.2255		
Total	19	6.8495				

Expected Mean Squares, using Adjusted SS

Source	Expected Mean Square for Each Term
1 Lab	(2) + 5.0000(1)
2 Error	(2)

Sett opp en modell for dette forsøket og gjør rede for hvilke forutsetninger vi gjør for analysen. Er det grunnlag for å påstå at det er forskjeller mellom laboratoriene? Bruk 5% signifikansnivå. Estimer varianskomponentene.

Oppgave 1

X_i binomisk fordelt derom

- 200 uavhengige forsøk
- Observerer fjører med sprøkk / ikke sprøkk
- $P(\text{sprøkk}) = p$ for kvar fjør.

$X_i \sim B(200, p) \Rightarrow Y_i$ (talet på fjører utan sprøkk)

er $B(200, 1-p)$



$SD(X_i) = SD(Y_i) = \sqrt{np(1-p)} = \sqrt{200 \cdot p(1-p)}$

$1 - \hat{p} = 0.7 \Rightarrow \hat{p} = 0.3$ og $\hat{\sigma}_{\hat{p}} = \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} = \sqrt{\frac{0.3 \cdot 0.7}{200}} = 0.0324$

$\hat{p} \pm 3\hat{\sigma}_{\hat{p}} \Rightarrow \begin{cases} UCL = 0.3972 \\ LCL = 0.2028 \end{cases}$

For X_i

For Y_i



$\min(np, n(1-p)) = 200 \cdot 0.3 = 60 > 5 \Rightarrow$ binomisk fordeling kan approksimerast med normalfordeling.

$H_0: \mu_{20} = \mu_{50} \quad H_1: \mu_{20} \neq \mu_{50}$

20°C $X_i, i=1, 2, \dots, 4 \sim N(\mu_{20}, \sigma^2)$ og uavh.

50°C $Y_i, i=1, 2, \dots, 4 \sim N(\mu_{50}, \sigma^2)$ og uavh. og uavh. av $X_i, i=1, 2, \dots, 4$.

$$T = \frac{\bar{x} - \bar{y}}{s_p \sqrt{\frac{1}{4} + \frac{1}{4}}} \quad \text{div } s_p = \frac{\sum_{i=1}^4 (x_i - \bar{x})^2 + \sum_{i=1}^4 (y_i - \bar{y})^2}{6}$$

ordi = 0,59 giver ingen grund til at forkaste.

2) 2^{3-1} forsøke, $I = ABC$

$$A = A + BC$$

$$B = B + AC$$

$$C = C + AB$$

$$l_A = \frac{79 + 87 - (59 + 61)}{2} = 23$$

$$l_B = \frac{87 + 61 - (79 + 59)}{2} = 5$$

$$l_C = \frac{59 + 87 - (61 + 79)}{2} = 3$$

$$\hat{A} = \frac{l_A + l_A'}{2} = \frac{23 + 23}{2} = 23$$

$$\hat{B} = \frac{l_B + l_B'}{2} = \frac{5 - 15}{2} = -5$$

$$\hat{C} = \frac{l_C + l_C'}{2} = \frac{3 + 0}{2} = 1,5$$

$$\hat{AC} = \frac{l_B - l_B'}{2} = \frac{5 + 15}{2} = 10$$

$$e) \sigma_{\text{eff}}^2 = \frac{4\sigma^2}{16} = \frac{\sigma^2}{4}, \quad \sigma_{\text{eff}}^2 = \frac{4,583}{4} = 1,146$$

$$\text{Kritiske verdi} = \sqrt{1,146} \cdot t_{0,025,6} = \sqrt{1,146} \cdot 2,45 = 2,62$$

\Rightarrow A, B og AC er signifikante

reduksjon av karbon fra 0.7% til 0.5% kjem
 et estimert forventet auke i % feilfri fjøring med 6.
 det er eksempel mellom A og C. Vi har ikke alle
 observeringsoppsett, men høyt sett er

$$\hat{y} = 70.875 + \frac{22.25}{2}A - \frac{6}{2}B + \frac{11}{2}AC.$$

⇒ effekten av faktor A og C $\approx 11.125A + 5.5AC$

	A	-	+
C	-	-5.625	5.625
	+	-16.625	16.625

Som synes at effekten av å auke stat temperaturen
 er mye større når olje-temperaturen er 50°C enn når den
 er 20. Best effekten får vi A og C er på høgt nivå.

(1) Siden blokkdelinga er ortogonal på kontrastkolonnene
 (like mange + og - i kvar blokk) vil alle effekter
 bli kansellert når vi midlar dei 4 observasjonane i kvar blokk

derfor er $\overline{\text{Blokk 1}} = 71, \overline{\text{Blokk 2}} = 71 + 0.5 = 71.5$
 $\overline{\text{Blokk 3}} = 71 - 1.5 = 69.5, \overline{\text{Blokk 4}} = 71 + 0.5 = 71.5$

$\bar{y} = 70.875$

$$SS_{\text{blokk}} = 4 \left[(71 - 70.875)^2 + (71.5 - 70.875)^2 + (69.5 - 70.875)^2 + (71.5 - 70.875)^2 \right]$$

$$= 10.75.$$

$H_0: \beta_A = \beta_B = \beta_C = \beta_{AB} = \beta_{AC} = \beta_{BC} = 0$

$H_1: \text{minst ein} \neq 0.$

$SS_R = 2660.25 - 10.75 = 2649.50$

(4)

$$F = \frac{\frac{SSR}{6}}{\frac{SSE}{9}} = \frac{\frac{2649.50}{6}}{\frac{38.25}{9}} = 103.9 \gg f_{0.05, 6, 9} = 3.37$$

\Rightarrow forkast H_0 . Regressionen har signifikant forklaringsgrad

$$R^2 = \frac{2649.50}{2687.50} = 98.6$$

$$\hat{y} = \bar{y} + \beta_A A + \beta_B B + \beta_{AC} AC$$

$$= 70.875 + 11.125A - 3B + 5.5AC$$

$$R^2 = \frac{1980.25 + 144 + 484}{2687.25} = \frac{2608.25}{2687.25} = 97.$$

$$\hat{y} = 70.875 + 11.125 + 3 + 5.5 = 90.5$$

$$s^2 = \frac{2687.25 - 2608.25}{12} = \frac{79}{12} = 6.62$$

$$\text{Var } \hat{y} = \text{Var}(\bar{y} + \hat{\beta}_A A + \hat{\beta}_B B + \hat{\beta}_{AC} AC)$$

$$= \frac{\sigma^2}{16} + \frac{\sigma^2}{16} + \frac{\sigma^2}{16} + \frac{\sigma^2}{16} = \frac{\sigma^2}{4}$$

$$\text{Var}(y - \hat{y}) = \sigma^2 + \frac{\sigma^2}{4} = \frac{5\sigma^2}{4}$$

$$\text{Predikjonsintervall: } 90.5 \pm t_{0.025, 9} \cdot \sqrt{\frac{5}{4}} = 90.5 \pm 6.27 = (84.23, 96.77)$$

$$y_{ij} = \mu + d_j + \varepsilon_{ij} \sim N(0, \sigma_A^2)$$

$$H_0: \sigma_A^2 = 0 \quad H_1: \sigma_A^2 \neq 0$$

$$P\text{-verdi} = P(F_{3,16} \geq 4.79) = 0.014$$

\Rightarrow forkast H_0 på 5% nivå

$$E\left\{\frac{SS_L}{3}\right\} = \sigma^2 + 5\sigma_A^2$$

$$\Rightarrow \hat{\sigma}_A^2 = \frac{E\left\{\frac{SS_L}{3}\right\} - \hat{\sigma}^2}{5} = \frac{1.0805 - 0.2255}{5} = 0.171$$