

# Løsning Eksamen vår 2015, stat100

## Oppgave 1

A)  $Y_i = \alpha + \beta x_i + e_i$  der  $e_i$ -ene er uavhengige og normalfordelt  $(0, \sigma)$ , der  $Y_i$  er kalori-mengde og  $x_i$  er fettmengde for hamburger nummer  $i$ ,  $i = 1, 2, \dots, 18$ .

$\beta$  er forventet (gjennomsnittlig) økning i kilokalori (pr 100 gram) for hver gang fettprosenten øker med 1.

$\alpha$  er forventet (gjennomsnittlig) kalorimengde for hamburgere uten fett, dette er meningsløst av to grunner, slike hamburgere finnes neppe og våre data er ikke hentet fra områder nesten uten fett.

$\sigma$  er et mål for variasjon (i betydning standardavvik) i kalorimengde for alle hamburgere med samme fettprosent.

$$\hat{\alpha} = 126,92$$

Estimater:  $\hat{\beta} = 10,25$

$$\hat{\sigma} = 33,08$$

$$\text{B) } R^2 = \frac{\text{SSRegression}}{\text{SSRegression} + \text{SSError}} = \frac{\text{SSFett}}{\text{SSFett} + \text{SSResiduals}} = \frac{98172}{98172 + 17507} = 0,849$$

I dette datasettet er det slik at omtrent 85 % av variasjonen i kalorier, kan forklares av variasjonen i fettprosent.

$$\text{C) } 95 \% \text{ KI er gitt ved } (\hat{\beta} \pm t_{0,025,16} \text{SE}(\hat{\beta})), \text{ eller } (10,25 \pm 2,12 * 1,082) = (7,96; 12,54)$$

Vi ser at 9 ligger inne i intervallet, dermed har vi ikke klart å påvise noen motsetninger med ekspertene. Vi kan ikke forkaste  $H_0$  på 5 % nivå der  $H_0: \beta = 9$  mot  $H_1: \beta \neq 9$ .

D) Generelt: Skal teste  $H_0: \theta = \theta_0$  mot  $H_1: \theta \neq \theta_0$ , for en eller annen parameter  $\theta$  på nivå  $\alpha$ . Dersom du lager et  $(1 - \alpha) * 100\%$  KI for  $\theta$  og dette inneholder  $\theta_0$  kan du ikke forkaste  $H_0$ . Omvendt: Hvis intervallet ikke inneholder  $\theta_0$ , så kan du forkaste  $H_0$  og tro på  $H_1$ . Dermed blir et konfidensintervall en samling av nullhypoteser som ikke kan forkastes.

Spesielt her vi lager et 95 % KI for  $\beta$ . Dersom du vil teste  $H_0: \beta = \beta_0$  mot  $H_1: \beta \neq \beta_0$ , på nivå 0,05, og lager 95% KI for  $\beta$  og dette inneholder verdien  $\beta_0$ , kan du ikke forkaste  $H_0$ .

$$\text{E) } \hat{Y} = \hat{\alpha} + \hat{\beta} * 16,6 = 126,92 + 10,25 * 16,6 = 297,07$$

95 % PI for antall kilokalorier er gitt ved:

$$\hat{Y} \pm t_{0,025,16} \hat{\sigma} \sqrt{1 + \frac{1}{n}} = (297 \pm 2,12 * 33,08 \sqrt{\frac{19}{18}}) = 297 \pm 72 = (225; 369)$$

Generelt er bredden:  $2t_{0,025,16} \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$ , men når ny  $x$  er lik gjennomsnittet fal-

ler siste brøk under rottegnet ut og vi får minimal bredde.

F) Residual er:

Observasjon – Tilpasset verdi,  
For første hamburger blir det:  
 $289 - (126,92 + 10,25 \cdot 17) = 289 - 301 = -12$ .

Denne observasjonen inneholder 12 kilokalorier mindre enn hva vi anslår den til ut fra fettinnholdet.


Kan ikke se noe fra figur 1 eller figur 2 som tyder på alvorlige brudd med modellantagelsene. Det være seg linearitet, konstant varians eller normalfordeling.

**G** Se på figur 3, to fenomener synes klare. Linja har nesten ikke fall eller stigning, dermed betyr det at protein ikke har særlig betydning. I tillegg er  $R^2$  nesten 0, dermed er svært lite av den observerte variasjon i kalori-innhold forklart gjennom variasjon i protein. Sammenhengen mellom protein og kalori er derfor heller ikke signifikant (p-verdi er 0,826).

Hvis  $\beta = 0$ , da er  $P(|\hat{\beta}| \geq 0,7815) = 0,826$ . Det er dette som er definisjonen av en p-verdi.

**H** En rett linje kan ikke fange opp dette utsagnet: *Folk liker hamburgere med noe fett, men ikke for mye.*

En må ha et toppunkt omtrent mellom maksimal og minimal fettverdi. Figur 4 viser at en har negative residualer ved lave og høye verdier av tilpasset poeng, mens de er positive ved middels verdier. Positive residualer tyder på at folk gir mer poeng enn det en lineærmodell skulle tilsi, og dette gjelder da for middels feite hamburgere. For de magre og de feite gir modellen lavere poeng enn det som lineærmodellen tilsier. Altså må det være en ikke-lineær sammenheng ute og går, som har et toppunkt på middels feite hamburgere. For eksempel vil muligens en annengradskurve fange opp sammenhengen. Under ser du det eksakte spredningsplottet, du trenger bare i skissere sånn omtrent hvordan det ser ut.



<b>Opp-gave</b>	<b>A</b>	<b>B</b>	<b>C</b>	<b>D</b>	<b>E</b>	<b>F</b>
<b>1</b>				O		
<b>2</b>	O					
<b>3</b>						O
<b>4</b>		O				
<b>5</b>		O				
<b>6</b>						O
<b>7</b>			O			
<b>8</b>						O
<b>9</b>	O					
<b>10</b>	O					
<b>11</b>	O					
<b>12</b>						O
<b>13</b>	O					
<b>14</b>					O	
<b>15</b>		O				
<b>16</b>					O	
<b>17</b>						O
<b>18</b>				O		
<b>19</b>		O				
<b>20</b>		O				