

## Tentamen i Regressions- och tidsserieanalys, (4,5 hp)

### Kurs: Regressionsanalys och undersökningsmetodik

2020-01-13

---

**Skrivtid:** kl. 9.00 - 14.00 (5 timmar)  
**Godkända hjälpmedel:** Miniräknare utan lagrade formler och text  
**Vidhäftade hjälpmedel:** Formelsamling och Statistiska tabeller (endast de tabeller som krävs)

- Tentamen består av 5 uppgifter, i förekommande fall uppdelade i deluppgifter. Maximalt antal poäng anges per deluppgift.
- Svar med fullständiga redovisningar ska lämnas.
  - Använd endast skrivpapper som tillhandahålls i skrivsalen.
  - För full poäng på en uppgift krävs tydliga, utförliga och väl motiverade lösningar.
  - Kontrollera alltid dina beräkningar och lösningar! Slarvfel kan också ge poängavdrag!
  - Använd minst fem värdesiffror i dina beräkningar (1,2345 och 1234,5 är exempel på tal med fem värdesiffror). I förekommande fall är det inte möjligt pga. avrundning i t.ex. SAS-utskrifter men utgå då ifrån det som är givet. Du kan dock avrunda ditt slutliga svar.
- Tentamen kan maximalt ge 100 poäng och för godkänt resultat krävs minst 50.
- Betygsgränser:
  - A: 90 – 100 p
  - B: 80 – 89 p
  - C: 70 – 79 p
  - D: 60 – 69 p
  - E: 50 – 59 p
  - Fx: 40 – 49 p
  - F: 0 – 40 p

OBS! Fx och F är underkända betyg som kräver omexamination. Studenter som får betyget Fx kan alltså inte komplettera för högre betyg.

- Lösningförslag läggs ut på Athena kort efter tentamen.

**LYCKA TILL!**

### Uppgift 1. (30p)

Ett företag analyserar ett antal utvecklingsprojekt som genomfördes för ett par år sedan. Man antar att  $Y$  = den årliga vinsten av ett genomfört projekt kan förklaras av  $X$  = projektbudgetens storlek, båda i mkr, enligt en linjär modell:

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma_\varepsilon^2)$$

Dina underlag förlorades när din hårddisk kraschade men du hittar en utskrift med följande sammanställning:

Projekt $i$	1	2	3	4	5	6	7	8	9	10	Summa
$x_i$	3	5	5	7	9	9	11	13	13	15	90
$y_i$	10	14	12	18	23	18	20	22	21	19	177
$x_i^2$	9	25	25	49	81	81	121	169	169	225	954
$y_i^2$	100	196	144	324	529	324	400	484	441	361	3303
$x_i y_i$	30	70	60	126	207	162	220	286	273	285	1719
$e_i$	-2,45	-0,20	-2,20	2,05	5,30	0,30	0,55	0,80	-0,20	-3,95	0,00

- Skatta parametrarna i modellen med minsta-kvadrat-metoden. (6p)
- Beräkna residualvariansen. (4p)
- Beräkna förklaringsgraden och förklara kortfattat vad detta är så att din chef förstår. (6p)
- Beräkna ett 95% prediktionsintervall för den vinsten när  $X = 10$ . Förklara kortfattat vad detta intervall säger oss så att din chef förstår. (8p)
- Åskådliggör  $X$  och  $Y$  i ett spridningsdiagram tillsammans med den skattade regressionslinjen och kommentera kortfattat. Är modellen lämplig för dessa data eller vill du justera den på något sätt? (6p)

### Uppgift 2. (20p)

För var och en av följande deluppgifter ska du svara kortfattat. Hela uppgiften bör kunna redovisas på en eller max två A4-sidor. Du får gärna komplettera med bilder och skisser.

- Förklara begreppen homoskedasticitet respektive heteroskedasticitet. Vilket av dessa föredras i en linjär regressionsmodell med intercept? (5p)
- Förklara begreppet extrapolering. Vad ska man tänka på när man extrapolerar? (5p)
- Vad är skillnaden mellan ett konfidensintervall för  $\mu_{Y|X=x}$  och ett prediktionsintervall för  $Y|X = x$ ? (5p)
- Vad är skillnaden mellan felterm och residual? Är inte det samma sak? (5p)

### Uppgift 3. (30p)

Man ville veta om studenters resultat på en delkurs B i ett visst ämne kunde prediceras av deras resultat på delkurs A (som kommer före B) och deras gymnasiebetyg. Från ett stickprov skattade man den linjära regressionsmodellen:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$$

där  $Y$  = poäng på B-kursens slutprov,  $X_1$  = poäng på A-kursens slutprov och  $X_2$  är betyg från gymnasiet (på en skala 0-20). Nedan finner du en SAS-utskrift med resultat. Notera att en del saknas och du måste räkna ut en del av dessa för hand.

- Ange de fem grundantaganden som gäller för modellen ovan och ge exempel för tre av dessa på hur man kan undersöka om de är uppfyllda eller inte. (8p)
- Genomför ett formellt test på 5% signifikansnivå för att pröva om modellen som helhet är signifikant. Ange hypoteserna som du testar, testvariabel och dess fördelning, beslutsregel med kritiska gräns samt beräkningar och slutsats med förklaring. (8p)
- Beräkna två konfidensintervall för lutningskoefficienten  $\beta_2$ , ett med 95% och ett med 99% konfidensgrad. Vilken slutsats drar du från dessa två intervall? Vad är det för hypoteser som du implicit testar för genom att analysera intervallen? (8p)
- Variansinflationsfaktorn, som finns i utskriften, indikerar om det finns ett starkt linjärt samband mellan förklaringsvariablerna. Ange om du anser att faktorn är för hög eller om den är ok (2p). Beräkna sedan utifrån det angivna värdet, korrelationen mellan  $X_1$  och  $X_2$ . (4p)

Number of Observations Read	30
Number of Observations Used	30

Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model		7486.785			
Error		3056.681			
Total		10543.467			

Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t	Variance Inflation
Intercept	1	0.28251	14.5251			0
Prov A	1	0.59358	0.15442			2.00603
Gymn Betyg	1	2.81326	1.20348			2.00603

### Uppgift 4. (10p)

Logistisk regression har använts för att modellera sannolikheten att kunder uppskattar en viss mjukvaruprodukt beroende på hur mycket man har använt den:

$$\text{LogOdds}(Y = 1|x) = \beta_0 + \beta_1 x$$

där

$$Y = \begin{cases} 1, & \text{uppskattar produkten} \\ 0, & \text{uppskattar ej produkten} \end{cases} \quad x = \text{användning i timmar}$$

Från ett stickprov om  $n = 20$  observationer skattades modellen med SAS och man fick bland annat resultaten nedan; se även den anpassade kurvan i diagrammet på nästa sida.

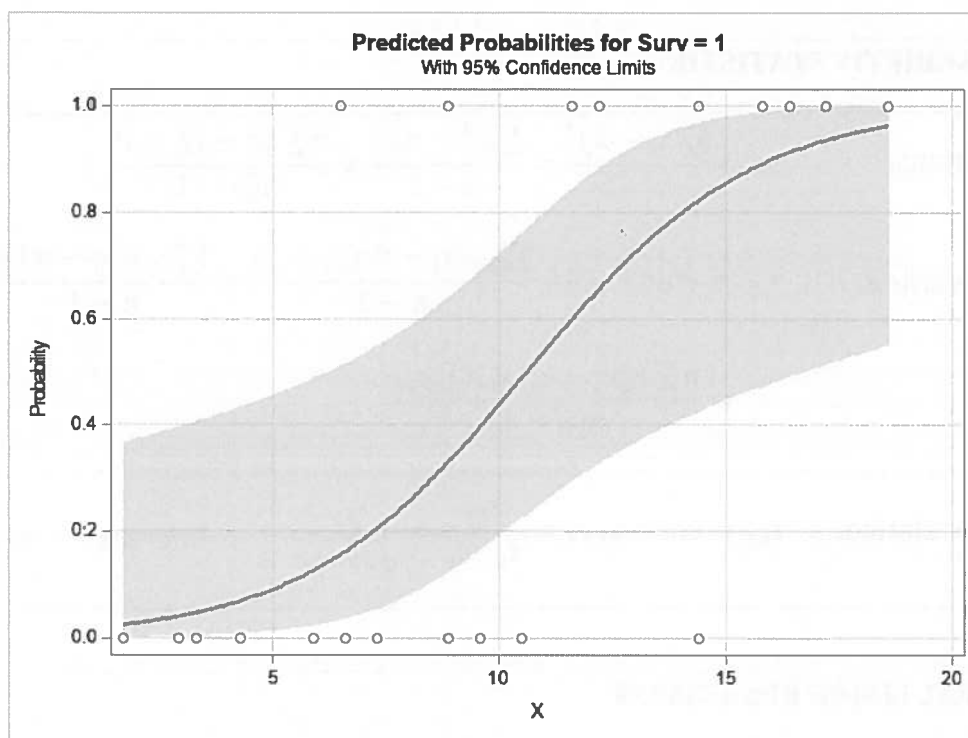
Response Profile		
Ordered Value	Y	Total Frequency
1	0	11
2	1	9

Analysis of Maximum Likelihood Estimates					
Parameter	DF	Estimate	Standard Error	Wald Chi-Square	Pr > ChiSq
Intercept	1	-4.3166	1.8405	5.5004	0.0190
X	1	0.4067	0.1705	5.6920	0.0170

Odds Ratio Estimates		
Effect	Point Estimate	95% Wald Confidence Limits
X	1.502	

- a) Välj ett av följande två alternativ att lösa. OBS! Du kan maximalt få 5p även om du gör båda.
- Alt 1. Använd diagrammet på nästa sida och ange ett ungefärligt värde på  $x$  när sannolikheten  $P(Y = 1|x) = 0.50$ . Vad kallas detta värde? Observera att du inte behöver genomföra några beräkningar. (2p)
- Alt 2. Beräkna det exakta värdet på  $x$  som ger  $P(Y = 1|x) = 0.50$ . TIPS:  $\text{Odds}(Y = 1|x) = P(Y = 1|x)/P(Y = 0|x)$ . Utnyttja formelsamlingen och använd punktskattningarna i utskriften ovan. (5p)
- b) Beräkna ett 95% konfidensintervall för oddskvoten  $OR(X)$ . Intervallgränserna har "ramlat bort" i utskriften ovan men du har standardfelet för skattningen av  $\beta_1$ . Utifrån detta intervall, skulle du påstå att antalet timmar har en signifikant effekt på sannolikheten  $P(Y = 1|x)$ ? Om du inte lyckas beräkna intervallet kan du ändå ange vad du tittar efter med intervallet. (5p)

(forts. uppgift 4)



### Uppgift 5. (10p)

I tabellen nedan visas  $y_t$  = produktionen (i mkr) för ett stort företag per kvartal under tre år. Du ser också att  $\hat{T}_t$  = trenden redan har skattats med centerade glidande medelvärden.

- Trendensa serien. Du kan använda antingen en additiv eller multiplikativ modell och du behöver inte motivera ditt val av modell, ange dock vilken du har använt och hur trendrensningen går till. (4p)
- Beräkna de fyra justerade säsongindexen, ett index för varje kvartal. (6p)

År	Kvartal	$t$	$y_t$	$\hat{T}_t$
2016	Kv1	1	156	*
	Kv2	2	76	*
	Kv3	3	116	168
	Kv4	4	304	180
2017	Kv1	5	196	196
	Kv2	6	132	208
	Kv3	7	188	220
	Kv4	8	328	236
2018	Kv1	9	268	252
	Kv2	10	188	268
	Kv3	11	260	*
	Kv4	12	384	*

# FORMELSAMLING

## DESKRIPTIV STATISTIK

Varians:	$s_x^2 = \frac{\sum(x_i - \bar{x})^2}{n-1} = \frac{\sum x_i^2 - n\bar{x}^2}{n-1} = \frac{n\sum x_i^2 - (\sum x_i)^2}{n(n-1)}$	
Kovarians:	$s_{xy} = cov(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1} = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{n-1}$ $= \frac{n\sum x_i y_i - (\sum x_i)(\sum y_i)}{n(n-1)}$	
Korrelation:	$r_{xy} = corr(x, y) = \frac{s_{xy}}{s_x \cdot s_y} = \frac{s_{xy}}{\sqrt{s_x^2 \cdot s_y^2}}$	Inferens: $t_{n-2} = \frac{r_{xy}\sqrt{n-2}}{\sqrt{1-r_{xy}^2}}$

## ENKEL LINJÄR REGRESSION

Modell: $Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$	Betingat medelvärde för $Y X = x$ : $\mu_{Y X=x} = \beta_0 + \beta_1 x$
---	---

Parameterskattningar och dessas varianser:	$b_1 = \frac{s_{xy}}{s_x^2} = r_{xy} \cdot \frac{s_y}{s_x}$	$s_{b_1}^2 = \frac{s_e^2}{(n-1)s_x^2} = \frac{s_e^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$
	$b_0 = \bar{y} - b_1 \bar{x}$	$s_{b_0}^2 = s_e^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{(n-1)s_x^2} \right)$

Prediktion och skattat betingat medelvärde:	$\hat{y}_i = \hat{\mu}_{Y X=x_i} = b_0 + b_1 x_i$
---	---

Prediktionsintervall för prediktionen $\hat{y}_i$ givet $X = x$ :	$\hat{y}_i \pm t_{n-2, \alpha/2} \cdot \sqrt{s_e^2 \left( 1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{(n-1)s_x^2} \right)}$
---	--

Konfidensintervall för betingade medelvärdet $\mu_{Y X=x}$ givet $X = x$ :	$\hat{\mu}_{Y X=x} \pm t_{n-2, \alpha/2} \cdot \sqrt{s_e^2 \left( \frac{1}{n} + \frac{(x - \bar{x})^2}{(n-1)s_x^2} \right)}$
--	--

## ICKE-LINJÄR REGRESSION, exempel

Andragsgradspolynom:	$\hat{y}_i = a + b_1 x_i + b_2 x_i^2$
Exponentiell:	$\ln(\widehat{y}_i) = a + b x_i \quad \hat{y}_i = \exp(a + b x_i) = (e^a)(e^b)^{x_i} = (a') \cdot (b')^{x_i}$ $\log_{10}(\widehat{y}_i) = a + b x_i \quad \hat{y}_i = (10^a)(10^b)^{x_i} = (a') \cdot (b')^{x_i}$

## ENKEL OCH MULTIPLE LINJÄR REGRESSION (sätt $k = 1$ om enkel regression)

$$\text{Residualvarians: } s_e^2 = \frac{\sum_{i=1}^n e_i^2}{n - k - 1} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - k - 1} = \frac{SSE}{n - k - 1} = MSE$$

$$\text{Kvadratsummor: } SST = \sum_{i=1}^n (y_i - \bar{y})^2 = (n - 1)s_y^2 = SSR + SSE$$

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n e_i^2 = (n - k - 1)s_e^2$$

$$SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = [\text{om enkel regression}] = b^2 \sum_{i=1}^n (x_i - \bar{x})^2$$

$$\text{Förklaringsgrad: } R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad R_{\text{adj}}^2 = 1 - \frac{SSE/(n - k - 1)}{SST/(n - 1)}$$

$$\text{Inferens för } \beta_j: \quad \text{KI: } b_j \pm t_{n-k-1, \alpha/2} \cdot s_{b_j} \quad \text{Test: } t_{n-k-1} = \frac{b_j - \beta_j^*}{s_{b_j}}$$

$$\text{Test för hela modellen: } F_{k, n-k-1} = \frac{SSR/K}{SSE/(n - K - 1)} = \frac{MSR}{MSE}$$

## Beräkningsformler för KORRELATION och REGRESSIONSKOEFFICIENT

$$\begin{aligned} b_1 &= \frac{n \sum x_i y_i - (\sum x_i)(\sum y_i)}{n \sum x_i^2 - (\sum x_i)^2} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \\ &= \frac{\sum (x_i - \bar{x})(y_i - \bar{y}) / (n - 1)}{\sum (x_i - \bar{x})^2 / (n - 1)} = \frac{s_{xy}}{s_x^2} = \frac{s_{xy}}{s_x^2} \cdot \frac{s_x s_y}{s_x s_y} = \frac{s_{xy}}{s_x s_y} \cdot \frac{s_y}{s_x} = r_{xy} \cdot \frac{s_y}{s_x} \end{aligned}$$

$$\begin{aligned} r_{xy} &= \frac{n \sum x_i y_i - (\sum x_i)(\sum y_i)}{\sqrt{n \sum x_i^2 - (\sum x_i)^2} \cdot \sqrt{n \sum y_i^2 - (\sum y_i)^2}} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sqrt{\sum x_i^2 - n \bar{x}^2} \cdot \sqrt{\sum y_i^2 - n \bar{y}^2}} \\ &= \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \cdot \sqrt{\sum (y_i - \bar{y})^2}} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y}) / (n - 1)}{\sqrt{\sum (x_i - \bar{x})^2 / (n - 1)} \cdot \sqrt{\sum (y_i - \bar{y})^2 / (n - 1)}} \\ &= \frac{s_{xy}}{\sqrt{s_x^2} \cdot \sqrt{s_y^2}} = \frac{s_{xy}}{s_x s_y} = \frac{s_{xy}}{s_x s_y} \cdot \frac{s_x}{s_x} = \frac{s_{xy}}{s_x^2} \cdot \frac{s_x}{s_y} = b_1 \cdot \frac{s_x}{s_y} \end{aligned}$$

## TIDSSERIEANALYS

### - Komponenter

Additiv modell:  $Y_t = T_t + S_t + C_t + E_t$       Multiplikativ modell:  $Y_t = T_t \cdot S_t \cdot C_t \cdot E_t$

där  $T$  = trend,  $S$  = säsong,  $C$  = cyklisk/konjunktur samt  $E$  = slumpkomponent

### - Skattning av trendkomponenten:

- med glidande medelvärden utan säsongvariation, exempel:

3-punkter  
centrerat:  $\hat{T}_t = \frac{1}{3} \cdot y_{t-1} + \frac{1}{3} \cdot y_t + \frac{1}{3} \cdot y_{t+1}$

5-punkter  
centrerat:  $\hat{T}_t = \frac{1}{5} \cdot y_{t-2} + \frac{1}{5} \cdot y_{t-1} + \frac{1}{5} \cdot y_t + \frac{1}{5} \cdot y_{t+1} + \frac{1}{5} \cdot y_{t+2}$

- med centrerade glidande medelvärden med säsongvariation, exempel:

halvårsdata:  $\hat{T}_t = \frac{1}{4} \cdot y_{t-1} + \frac{1}{2} \cdot y_t + \frac{1}{4} \cdot y_{t+1}$

kvartalsdata:  $\hat{T}_t = \frac{1}{8} \cdot y_{t-2} + \frac{1}{4} \cdot y_{t-1} + \frac{1}{4} \cdot y_t + \frac{1}{4} \cdot y_{t+1} + \frac{1}{8} \cdot y_{t+2}$

månadsdata:  $\hat{T}_t = \frac{1}{24} \cdot y_{t-6} + \frac{1}{12} \cdot y_{t-5} + \dots + \frac{1}{12} \cdot y_{t+5} + \frac{1}{24} \cdot y_{t+6}$

- med regressionsanalys, linjär trend och exponentiell trend:

Modell:  $Y_t = \beta_0 + \beta_1 t + \varepsilon_1$       Skattad modell:  $\hat{y}_t = b_0 + b_1 t = \hat{T}_t$

$\ln Y_t = \beta_0 + \beta_1 t + \varepsilon_1$        $\hat{y}_t = \exp(b_0 + b_1 t) = \hat{T}_t$

### - Justering av säsongindex $\bar{S}_j$ med $p$ säsonger (halvår, kvartal el. månader osv.):

Additiv modell:  $S_j^+ = \bar{S}_j - \left( \frac{\sum \bar{S}_i}{p} \right)$       Multiplikativ modell:  $S_j^+ = \frac{\bar{S}_j}{(\sum \bar{S}_i / p)}$

### - Trend- och säsongrensning:

Additiv modell:  $y_t - \hat{T}_t$  resp.  $y_t - S_t^+$       Multiplikativ modell:  $y_t / \hat{T}_t$  resp.  $y_t / S_t^+$



## LOGISTISK REGRESSION och ODDS

Odds för en händelse A:	$\text{Odds}(A) = \frac{P(A)}{P(\bar{A})} = \frac{P(A)}{1 - P(A)} \Leftrightarrow P(A) = \frac{\text{Odds}(A)}{1 + \text{Odds}(A)}$
Oddsquot för händelsen A mot B:	$\text{OR} = \frac{\text{Odds}(A)}{\text{Odds}(B)}$

### - Logistisk regression:


Enkel modell:	$P(Y = 1 x) = \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 x)} = \frac{1}{1 + \exp(-\beta_0 - \beta_1 x)}$ $P(Y = 0 x) = \frac{1}{1 + \exp(\beta_0 + \beta_1 x)}$ $\text{Odds}(Y = 1 x) = \exp(\beta_0 + \beta_1 x)$ $\text{LogOdds}(Y = 1 x) = \beta_0 + \beta_1 x$
Multipel modell:	$\text{LogOdds}(Y = 1 x_1, \dots, x_k) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$

Intercept $\beta_0$ :	$P(Y = 1 x_1 = \dots = x_k = 0) = \frac{\exp(\beta_0)}{1 + \exp(\beta_0)}$
Oddsquot för $Y = 1$ när $X_j = x_j + 1$ mot $X_j = x_j$ :	$\text{OR}(X_j) = \frac{\text{Odds}(Y = 1 x_j + 1, \text{allt annat lika})}{\text{Odds}(Y = 1 x_j, \text{allt annat lika})} = \exp(\beta_j)$
KI för $\text{OR}(X_j)$ :	$\left( \exp(b_j - z_{\alpha/2} \cdot s_{b_j}); \exp(b_j + z_{\alpha/2} \cdot s_{b_j}) \right)$

**TABELL 3.** t-fördelningens kvantiler

$T \in t(v)$  där  $v$  = antal frihetsgrader.

Vilket värde har  $t_\alpha$  om  $P(T > t_\alpha) = \alpha$  där  $\alpha$  är en given sannolikhet. Utnyttja även  $P(T \leq -t_\alpha) = P(T > t_\alpha)$ .



$v$	$\alpha = 0,1$	0,05	0,025	0,010	0,005	0,0025	0,0010	0,0005
1	3,078	6,314	12,706	31,821	63,657	127,321	318,309	636,619
2	1,886	2,920	4,303	6,965	9,925	14,089	22,327	31,599
3	1,638	2,353	3,182	4,541	5,841	7,453	10,215	12,924
4	1,533	2,132	2,776	3,747	4,604	5,598	7,173	8,610
5	1,476	2,015	2,571	3,365	4,032	4,773	5,893	6,869
6	1,440	1,943	2,447	3,143	3,707	4,317	5,208	5,959
7	1,415	1,895	2,365	2,998	3,499	4,029	4,785	5,408
8	1,397	1,860	2,306	2,896	3,355	3,833	4,501	5,041
9	1,383	1,833	2,262	2,821	3,250	3,690	4,297	4,781
10	1,372	1,812	2,228	2,764	3,169	3,581	4,144	4,587
11	1,363	1,796	2,201	2,718	3,106	3,497	4,025	4,437
12	1,356	1,782	2,179	2,681	3,055	3,428	3,930	4,318
13	1,350	1,771	2,160	2,650	3,012	3,372	3,852	4,221
14	1,345	1,761	2,145	2,624	2,977	3,326	3,787	4,140
15	1,341	1,753	2,131	2,602	2,947	3,286	3,733	4,073
16	1,337	1,746	2,120	2,583	2,921	3,252	3,686	4,015
17	1,333	1,740	2,110	2,567	2,898	3,222	3,646	3,965
18	1,330	1,734	2,101	2,552	2,878	3,197	3,610	3,922
19	1,328	1,729	2,093	2,539	2,861	3,174	3,579	3,883
20	1,325	1,725	2,086	2,528	2,845	3,153	3,552	3,850
21	1,323	1,721	2,080	2,518	2,831	3,135	3,527	3,819
22	1,321	1,717	2,074	2,508	2,819	3,119	3,505	3,792
23	1,319	1,714	2,069	2,500	2,807	3,104	3,485	3,768
24	1,318	1,711	2,064	2,492	2,797	3,091	3,467	3,745
25	1,316	1,708	2,060	2,485	2,787	3,078	3,450	3,725
26	1,315	1,706	2,056	2,479	2,779	3,067	3,435	3,707
27	1,314	1,703	2,052	2,473	2,771	3,057	3,421	3,690
28	1,313	1,701	2,048	2,467	2,763	3,047	3,408	3,674
29	1,311	1,699	2,045	2,462	2,756	3,038	3,396	3,659
30	1,310	1,697	2,042	2,457	2,750	3,030	3,385	3,646
35	1,306	1,690	2,030	2,438	2,724	2,996	3,340	3,591
40	1,303	1,684	2,021	2,423	2,704	2,971	3,307	3,551
45	1,301	1,679	2,014	2,412	2,690	2,952	3,281	3,520
50	1,299	1,676	2,009	2,403	2,678	2,937	3,261	3,496
55	1,297	1,673	2,004	2,396	2,668	2,925	3,245	3,476
60	1,296	1,671	2,000	2,390	2,660	2,915	3,232	3,460
65	1,295	1,669	1,997	2,385	2,654	2,906	3,220	3,447
70	1,294	1,667	1,994	2,381	2,648	2,899	3,211	3,435
75	1,293	1,665	1,992	2,377	2,643	2,892	3,202	3,425


Forts. nästa sida

**TABELL 3 forts. t-fördelningens kvantiler**

<b>v</b>	<b><math>\alpha = 0,1</math></b>	<b>0,05</b>	<b>0,025</b>	<b>0,010</b>	<b>0,005</b>	<b>0,0025</b>	<b>0,0010</b>	<b>0,0005</b>
<b>80</b>	1,292	1,664	1,990	2,374	2,639	2,887	3,195	3,416
<b>85</b>	1,292	1,663	1,988	2,371	2,635	2,882	3,189	3,409
<b>90</b>	1,291	1,662	1,987	2,368	2,632	2,878	3,183	3,402
<b>95</b>	1,291	1,661	1,985	2,366	2,629	2,874	3,178	3,396
<b>100</b>	1,290	1,660	1,984	2,364	2,626	2,871	3,174	3,390
<b>125</b>	1,288	1,657	1,979	2,357	2,616	2,858	3,157	3,370
<b>150</b>	1,287	1,655	1,976	2,351	2,609	2,849	3,145	3,357
<b>175</b>	1,286	1,654	1,974	2,348	2,604	2,843	3,137	3,347
<b>200</b>	1,286	1,653	1,972	2,345	2,601	2,839	3,131	3,340
<b>300</b>	1,284	1,650	1,968	2,339	2,592	2,828	3,118	3,323
<b>400</b>	1,284	1,649	1,966	2,336	2,588	2,823	3,111	3,315
<b>500</b>	1,283	1,648	1,965	2,334	2,586	2,820	3,107	3,310
<b>1000</b>	1,282	1,646	1,962	2,330	2,581	2,813	3,098	3,300
<b>2000</b>	1,282	1,646	1,961	2,328	2,578	2,810	3,094	3,295
<b>3000</b>	1,282	1,645	1,961	2,328	2,577	2,809	3,093	3,294
<b>4000</b>	1,282	1,645	1,961	2,327	2,577	2,809	3,092	3,293
<b>5000</b>	1,282	1,645	1,960	2,327	2,577	2,808	3,092	3,292

**TABELL 5.** F-fördelningens kvantiler

$X \in F(v_1, v_2)$  där  $v_1, v_2$  = antal frihetsgrader i täljaren respektive nämnaren. Vilket värde har  $f_\alpha$  om  $P(X > f_\alpha) = \alpha$  där  $\alpha$  är en given sannolikhet.



$\alpha = 0,05$

	V1 =														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
<b>V2 = 1</b>	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9	243,0	243,9	244,7	245,4	245,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40	19,40	19,41	19,42	19,42	19,43
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79	8,76	8,74	8,73	8,71	8,70
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96	5,94	5,91	5,89	5,87	5,86
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74	4,70	4,68	4,66	4,64	4,62
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06	4,03	4,00	3,98	3,96	3,94
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64	3,60	3,57	3,55	3,53	3,51
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35	3,31	3,28	3,26	3,24	3,22
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14	3,10	3,07	3,05	3,03	3,01
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98	2,94	2,91	2,89	2,86	2,85
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85	2,82	2,79	2,76	2,74	2,72
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75	2,72	2,69	2,66	2,64	2,62
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67	2,63	2,60	2,58	2,55	2,53
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60	2,57	2,53	2,51	2,48	2,46
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54	2,51	2,48	2,45	2,42	2,40
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49	2,46	2,42	2,40	2,37	2,35
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45	2,41	2,38	2,35	2,33	2,31
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41	2,37	2,34	2,31	2,29	2,27
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38	2,34	2,31	2,28	2,26	2,23
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35	2,31	2,28	2,25	2,22	2,20
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24	2,20	2,16	2,14	2,11	2,09
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16	2,13	2,09	2,06	2,04	2,01
35	4,12	3,27	2,87	2,64	2,49	2,37	2,29	2,22	2,16	2,11	2,07	2,04	2,01	1,99	1,96
40	4,08	3,23	2,84	2,61	2,45	2,34	2,25	2,18	2,12	2,08	2,04	2,00	1,97	1,95	1,92
45	4,06	3,20	2,81	2,58	2,42	2,31	2,22	2,15	2,10	2,05	2,01	1,97	1,94	1,92	1,89
50	4,03	3,18	2,79	2,56	2,40	2,29	2,20	2,13	2,07	2,03	1,99	1,95	1,92	1,89	1,87
60	4,00	3,15	2,76	2,53	2,37	2,25	2,17	2,10	2,04	1,99	1,95	1,92	1,89	1,86	1,84
70	3,98	3,13	2,74	2,50	2,35	2,23	2,14	2,07	2,02	1,97	1,93	1,89	1,86	1,84	1,81
80	3,96	3,11	2,72	2,49	2,33	2,21	2,13	2,06	2,00	1,95	1,91	1,88	1,84	1,82	1,79
100	3,94	3,09	2,70	2,46	2,31	2,19	2,10	2,03	1,97	1,93	1,89	1,85	1,82	1,79	1,77
$\infty$	3,84	3,00	2,60	2,37	2,21	2,10	2,01	1,94	1,88	1,83	1,79	1,75	1,72	1,69	1,67

Forts. nästa sida

TABELL 5 forts. *F*-fördelningens kvantiler

$\alpha = 0,05$

	V1 =														
	16	17	18	19	20	25	30	35	40	50	60	70	80	100	$\infty$
V2 = 1	246,5	246,9	247,3	247,7	248,0	249,3	250,1	250,7	251,1	251,8	252,2	252,5	252,7	253,0	254,3
2	19,43	19,44	19,44	19,44	19,45	19,46	19,46	19,47	19,47	19,48	19,48	19,48	19,48	19,49	19,50
3	8,69	8,68	8,67	8,67	8,66	8,63	8,62	8,60	8,59	8,58	8,57	8,57	8,56	8,55	8,53
4	5,84	5,83	5,82	5,81	5,80	5,77	5,75	5,73	5,72	5,70	5,69	5,68	5,67	5,66	5,63
5	4,60	4,59	4,58	4,57	4,56	4,52	4,50	4,48	4,46	4,44	4,43	4,42	4,41	4,41	4,37
6	3,92	3,91	3,90	3,88	3,87	3,83	3,81	3,79	3,77	3,75	3,74	3,73	3,72	3,71	3,67
7	3,49	3,48	3,47	3,46	3,44	3,40	3,38	3,36	3,34	3,32	3,30	3,29	3,29	3,27	3,23
8	3,20	3,19	3,17	3,16	3,15	3,11	3,08	3,06	3,04	3,02	3,01	2,99	2,99	2,97	2,93
9	2,99	2,97	2,96	2,95	2,94	2,89	2,86	2,84	2,83	2,80	2,79	2,78	2,77	2,76	2,71
10	2,83	2,81	2,80	2,79	2,77	2,73	2,70	2,68	2,66	2,64	2,62	2,61	2,60	2,59	2,54
11	2,70	2,69	2,67	2,66	2,65	2,60	2,57	2,55	2,53	2,51	2,49	2,48	2,47	2,46	2,40
12	2,60	2,58	2,57	2,56	2,54	2,50	2,47	2,44	2,43	2,40	2,38	2,37	2,36	2,35	2,30
13	2,51	2,50	2,48	2,47	2,46	2,41	2,38	2,36	2,34	2,31	2,30	2,28	2,27	2,26	2,21
14	2,44	2,43	2,41	2,40	2,39	2,34	2,31	2,28	2,27	2,24	2,22	2,21	2,20	2,19	2,13
15	2,38	2,37	2,35	2,34	2,33	2,28	2,25	2,22	2,20	2,18	2,16	2,15	2,14	2,12	2,07
16	2,33	2,32	2,30	2,29	2,28	2,23	2,19	2,17	2,15	2,12	2,11	2,09	2,08	2,07	2,01
17	2,29	2,27	2,26	2,24	2,23	2,18	2,15	2,12	2,10	2,08	2,06	2,05	2,03	2,02	1,96
18	2,25	2,23	2,22	2,20	2,19	2,14	2,11	2,08	2,06	2,04	2,02	2,00	1,99	1,98	1,92
19	2,21	2,20	2,18	2,17	2,16	2,11	2,07	2,05	2,03	2,00	1,98	1,97	1,96	1,94	1,88
20	2,18	2,17	2,15	2,14	2,12	2,07	2,04	2,01	1,99	1,97	1,95	1,93	1,92	1,91	1,84
25	2,07	2,05	2,04	2,02	2,01	1,96	1,92	1,89	1,87	1,84	1,82	1,81	1,80	1,78	1,71
30	1,99	1,98	1,96	1,95	1,93	1,88	1,84	1,81	1,79	1,76	1,74	1,72	1,71	1,70	1,62
35	1,94	1,92	1,91	1,89	1,88	1,82	1,79	1,76	1,74	1,70	1,68	1,66	1,65	1,63	1,56
40	1,90	1,89	1,87	1,85	1,84	1,78	1,74	1,72	1,69	1,66	1,64	1,62	1,61	1,59	1,51
45	1,87	1,86	1,84	1,82	1,81	1,75	1,71	1,68	1,66	1,63	1,60	1,59	1,57	1,55	1,47
50	1,85	1,83	1,81	1,80	1,78	1,73	1,69	1,66	1,63	1,60	1,58	1,56	1,54	1,52	1,44
60	1,82	1,80	1,78	1,76	1,75	1,69	1,65	1,62	1,59	1,56	1,53	1,52	1,50	1,48	1,39
70	1,79	1,77	1,75	1,74	1,72	1,66	1,62	1,59	1,57	1,53	1,50	1,49	1,47	1,45	1,35
80	1,77	1,75	1,73	1,72	1,70	1,64	1,60	1,57	1,54	1,51	1,48	1,46	1,45	1,43	1,32
100	1,75	1,73	1,71	1,69	1,68	1,62	1,57	1,54	1,52	1,48	1,45	1,43	1,41	1,39	1,28
$\infty$	1,64	1,62	1,60	1,59	1,57	1,51	1,46	1,42	1,39	1,35	1,32	1,29	1,27	1,24	1,00





Stockholms  
universitet

Statistiska institutionen

## Rättningsblad

**Datum:** 13/1-2020

**Sal:** Värtasalen

**Tenta:** Regressions- och tidsserieanalys

**Kurs:** Regressionsanalys och undersökningsmetodik

**ANONYMKOD:**

0058-CRO

Jag godkänner att min tenta får läggas ut anonymt på hemsidan som studentsvar.

**OBS! SKRIV ÄVEN PÅ BAKSIDAN AV SKRIVBLADEN**

Markera besvarade uppgifter med kryss

1	2	3	4	5	6	7	8	9	Antal inl. blad
×	×	×	×	×					10
Lär.ant. 30	20	26	9	8					

POÄNG	BETYG	Lärarens sign.
93	A	ME





1.  $Y_i = \beta_0 + \beta_1 X_i + \epsilon_i$

a)  $\hat{y}_i = b_0 + b_1 X_i$

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n} = \frac{177}{10} = 17,7 \quad \bar{x} = \frac{\sum_{i=1}^n x_i}{n} = \frac{90}{10} = 9$$

$$b_1 = \frac{S_{xy}}{S_x^2} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} = \frac{1719 - 10 \cdot 17,7 \cdot 9}{954 - 10 \cdot 9^2}$$

$$= \frac{126}{144} = 0,875 \quad R$$

$$b_0 = \bar{y} - b_1 \bar{x} = 17,7 - 0,875 \cdot 9 = 9,825 \quad R$$


Svar:  $b_1 = 0,875 \quad b_0 = \alpha = 9,825 \quad /6$

b)  $S_e^2 = \frac{\sum_{i=1}^n \epsilon_i^2}{n - k - 1} = \frac{59,85}{10 - 1 - 1} = 7,48125 \quad R$

i	1	2	3	4	5	6	7	8	9	10	Summa
$\epsilon_i$	-2,45	-0,20	-2,20	2,05	5,30	0,30	0,55	0,90	-0,20	-3,45	0
$\epsilon_i^2$	6,0025	0,04	4,84	4,2025	28,09	0,09	0,3025	0,81	0,04	15,0025	59,85

$$\sum_{i=1}^n \epsilon_i^2 = 59,85$$

Svar:  $S_e^2 = 7,48125 \approx 7,4813 \quad /4$



$$1. \quad c). \quad R^2 = 1 - \frac{SSE}{SST} = 1 - \frac{59,85}{170,1} \approx 0,64815 \quad R$$

$$SSE = \sum_{i=1}^n e_i^2 = 59,85 \quad \left\{ \begin{array}{l} \text{Se uträkning} \\ \text{föregående deluppgift} \end{array} \right.$$

$$SST = (n-1)S_y^2 = (10-1) \cdot 18,9 = 170,1 \quad R$$

$$S_y^2 = \frac{\sum_{i=1}^n y_i^2 - n\bar{y}^2}{n-1} = \frac{3303 - 10 \cdot 17,7^2}{10-1} = \frac{170,1}{9} = 18,9$$

Förklaringsgraden är ett mått på hur mycket av variationen i  $y$  som kan förklaras av de oberoende förklaringsvariablerna  $x_k$  i modellen. Eftersom detta är en enkel regressionsmodell anger måttet hur mycket av variationen i  $y$  som kan förklaras av  $x_1$ .

Cirka 65% av variationen i den årliga vinsten av ett genomfört projekt kan alltså förklaras av variationen i projektbudgetens storlek. y

/6

1 d) 95% PI

$$\hat{y}_i \pm t_{n-2, \frac{\alpha}{2}} \cdot \sqrt{s^2_e \left( 1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{(n-1) s_x^2} \right)}$$

$$\hat{y}_i = 9,825 + 0,875x$$

$$\hat{y}_i | x=10 = 9,825 + 0,875(10) = 18,575$$

95% PI för  $\hat{y}_i | x=10$

$$18,575 \pm t_{8; 0,025} \cdot \sqrt{s^2_e \left( 1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{(n-1) s_x^2} \right)}$$

$$18,575 \pm 2,306 \cdot \sqrt{7,48125 \left( 1 + \frac{1}{10} + \frac{(10-9)^2}{(10-1) 161} \right)}$$

$$18,575 \pm 2,306 \cdot \sqrt{7,48125 \cdot 1,106944444}$$

$$18,575 \pm 2,306 \cdot 2,877729682$$

$$18,575 \pm 6,636044842$$


$$[11,939; 25,211]$$

med ca <sup>summa lönnar</sup> 95% ~~signifikansnivå~~ kan vi predicera att den framtida värderna på Y kommer ligga inom det givna intervallat då  $x=10$

Då projektbudgetens stl är 10 mkr kommer  $y$  = den årliga vinsten av ett genomfört projekt i framtiden ligga inom det givna intervallat med ca 95% (säkerhet) <sup>sannolikt</sup>

1 e)

$$\hat{y} = 9,824 + 0,875x$$




$$\hat{y}|x=15 = 9,824 + 0,875 \cdot 15 = 22,949$$

räknar ut  $\hat{y}$  för ett givet  $x$ -värde för att kunna rita linjen

modellen ser ut att vara lämplig. Regressionslinjen går igenom svärmen av plotten och det är ungefär lika mycket punkter under som över linjen. Men var ligger de under resp över?

16-

30



2 a) homoskedastisitet är fallet då feltermerna har en konstant varians, oberoende av värdena på  $X^n$  dvs

$$\sigma_{\epsilon_i}^2 = \sigma_{\epsilon}^2 \quad R$$

Heteroskedastisitet är det omvända dvs då feltermerna inte har en konstant varians oberoende av värdena på  $X^n$  dvs  $\sigma_{\epsilon_i}^2 \neq \sigma_{\epsilon}^2$

I en linjär regressionsmodell föredras homoskedastisitet annars kan det vara tvekan på det inte råder ett linjärt samband mellan  $X$  och  $Y$  eller att det råder linjära beroenden mellan prediktorvariablerna i en multipel linjär regressionsmodell. /5

b) extrapolering sker när man använder en modell för att undersöka  $\hat{Y}$  för sådana värden på  $X$  som inte fanns att tulla när man skattade koefficienterna i modellen. Det finns härmed en risk att modellen inte håller för dessa värden på  $X$  som inte användes vid skattningen av modellen  $\hat{Y}$  BRÅ!



man ska alltså vara försiktig när man extrapolerar, vara uppmärksam på avvikande observationer saknade outliers da detta kan vara en indikator på att modellen inte är användbar här.  $R$  ~~5~~

c). Ett konfidenstervall anger att med exempelvis 95% signifikansnivå kommer medelvärdet för stickprovet sammanfalla med det faktiska medelvärdet för populationen. Detta medelvärde sammanfaller i sin tur inom det givna intervall.

Ett prediktionsintervall anger istället vad framtida  $y$  men som vi inte ännu observerat kommer att komma med ex 95% säkerhet för 95% PI. Prediktionsintervall är längre än konfidenstervall eftersom det även rader en naturlig variation hos observationerna kring medelvärdet.  $R$  ~~5~~




2. d)

feltermerna betecknas  $\epsilon_i$  och är en slumpterm som inte går att observera i verkligheten därför används istället residualerna  $e_i$  som proxy för  $\epsilon_i$  vid beräkning och analysning av ett modelantaganden. För en linjär regressionsmodell är uppfylla exempelvis att feltermerna är normalfördelade och har en konstant varians, är oberoende sinsemellan och oberoende av  $x_i$ . Vi undersöker i bland annat olika typer av spänningsbegrepp

(Definiera gärna tydligare vad  $\epsilon_i$  och  $e_i$  är)

/5

20



3.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon$$

a) modelantaganden multipel linjär regressionsmodell

1. Det råder ett linjärt samband mellan den beroende  $Y$ -variabeln och förklaringsvariablerna  $X_1, \dots, X_K$  (~~plus en felterm  $\epsilon$~~ )  $\mathbb{R}$   
kan missförstås
2. feltermerna är oberoende sinsemellan  $\mathbb{R}$
3. feltermerna är oberoende av värdena på  $X_i$   $\mathbb{R}$
4. feltermerna är  $n$ fi med väntevärdet 0  $E_i \sim N(0, \sigma_{\epsilon}^2)$   $\mathbb{R}$
5. feltermerna har en konstant varians  $\sigma_{\epsilon}^2$   $\sigma_{\epsilon_i}^2 = \sigma_{\epsilon}^2$ . Feltermerna är med andra ord homoskedastiska  $\mathbb{R}$
6. prediktorvariablerna får korrelera med varandra men dem får inte vara linjärt bestämda av varandra så det existerar en uppställning konstanter  $\mathbb{R}$



Man kan undersöka att antagande nr. 6 är uppfyllt genom att beräkna VIF för modellen.  $VIF > 10$  eller t.o.m. större än 5 kan vara tecken på multikollinearitet  $R$

Man kan undersöka att antagande nr. 5 är uppfyllt genom att plotta residualerna mot dem motsvarande  $X_i$  värdena.

En mönster i spridningsdiagrammet  $R$  kan vara en indikator på heteroskedastiskitet

Man kan undersöka antagande 1 att det råder ett linjärt samband mellan  $Y$  och  $X$ 'n genom att beräkna F-värdet och jämföra det med motsvarande F-kvot för att se om modellen som helhet är signifikant skild från noll  $R$

8

3 b) Hypoteser

$$H_0: \beta_1 = \beta_2 = 0 \quad \alpha = 0,05$$

$$H_a: \text{någon av } \beta_1 \text{ eller } \beta_2 \neq 0 \quad \checkmark$$

Testvariabel

$$F = \frac{MSR}{MSE} \sim F_2; 27 \quad \checkmark$$

Fnhetsgrader

modell = k = 2

Error = n - k - 1 = 27

Total = n - 1 = 29

BeslutsregelFörkasta  $H_0$  om  $F_{obs} > F_{kritisk}$ 

$$F_{kritisk} = F_{2; 27; 0,05} \approx 3,32 - 3,39$$

(obs finns tj 27 frihetsgrader i tabellen men finns för 20 och 25 så någonstans mellan dessa två värden är  $F_{kritisk}$  BRA!)

$$MSR = SSR / k = ?$$

$$7486,785 / 2 = 3743,3925 \approx 3743,4$$

$$MSE = SSE / (n - k - 1) =$$

$$3056,681 / 27 =$$

$$113,2104074 \approx$$

$$113,21$$

Beräkningar

$$F_{obs} = \frac{MSR}{MSE} = \frac{3743,4}{113,21} \approx 33,066 \quad \checkmark$$

$$MST = SST / (n - 1)$$

$$= 10543,467 / 29$$

$$= 363,5678276 \approx$$

$$363,57$$

Slutsatser

$$F_{obs} = 33,066 > F_{krit} = 3,32 - 3,39$$

någon

Vi kan alltså på 5% signifikansnivå förkasta nollhypotesen och modellen som helhet är signifikant skild från noll. X variablerna är alltså förklarande variabler i Y i ett ensemble med varandra. /8

3c) 95% KI för  $\beta_2$

$$b_2 \pm t_{27; 0,025} \cdot S_{b_2}$$

$$2,81326 \pm 2,052 \cdot 1,20348$$

$$2,81326 \pm 2,46954096$$

$$0,34371904; 5,28280096$$

$$[0,3437; 5,2828] \text{ R}$$

Med 95%

säkerhet kommer det samma värdet på  $b_2$  dvs  $\beta_2$  hamna inom detta intervall

99% KI för  $\beta_2$

$$b_2 \pm t_{27; 0,005} \cdot S_{b_2}$$

$$2,81326 \pm 2,771 \cdot 1,20348$$

$$2,81326 \pm 3,33484308$$

$$-0,52158308; 6,14810308$$

$$[-0,52158; 6,1481] \text{ R}$$

Med 99% säkerhet kommer det samma värdet på  $b_2$  dvs  $\beta_2$  hamna inom detta intervall

implicit testar man för vilka värden på  $\beta_2$  som koefficienten är signifikant skild från noll dvs vilka värden på  $\beta_2$  koefficienten som krävs för att förklaringsvariabeln ämnar förklara variationen i  $Y$  dvs ger mervärde för modellen. Man ser efter om noll ligger i intervallet

$$H_0: \beta_2 = 0 \mid X_i \text{ i modellen}$$


$$H_1: \beta_2 \neq 0 \mid - \text{ -- } -$$

7

3 d) VIF värdet på 2,00603 anses jag är okej tumregeln är att VIF ska vara under 10 eller i vissa fall under 5. 2,00603 är alltså okej och tyder på att ingen multikollinearitet går att misstänka i modellen.

$$(r_{x_1 x_2} = s_{b_1} \cdot s_{b_2} = 0,15442 \cdot 1,20348 \approx 0,18584)$$

26





4 a)

$$\text{Odds}(y=1|x) = \frac{P(y=1|x)}{P(y=0|x)} = \frac{0,5}{0,5} = 1$$

$$\text{Log Odds}(y=1|x) = -4,3166 + 0,4067x = \log 1$$

$$-4,3166 + 0,4067x = 0$$

LÖSER UT X

$$0,4067x = 4,3166$$

$$x = \frac{4,3166}{0,4067} = 10,61372019 \approx 10,614$$

BRA!

/5

b) 95% KI för OR ( $x_j$ )

$$\left( \exp\left(b_j - \frac{z_{\alpha}}{2} \cdot s_{b_j}\right), \exp\left(b_j + \frac{z_{\alpha}}{2} \cdot s_{b_j}\right) \right)$$

$$\exp(0,4067 - 1,96 \cdot 0,1705); \exp(0,4067 + 1,96 \cdot 0,1705)$$

$$\exp(0,07252); \exp(0,74088)$$

$$e^{0,07252}, e^{0,74088}$$

$$1,07521431; 2,09779075$$

$$[1,0752; 2,0978] \quad \mathbb{R}$$

punktskattningen av OR ( $x$ ) = 1,502. Detta värde faller inom det givna intervallet och jag vill därför påstå att antalet

timmar har en signifikant effekt  
på sannolikheten  $P(Y=1|X)$

KI täcker tj värdet 1

4

9

5.

a) Trendriensning för Additiv modellen

$$t = y_t - \hat{T}_t$$

1	$y_1 - \hat{T}_1 = 156 - * = 0$	KV 1	räknes ej	
2	$y_2 - \hat{T}_2 = 76 - * = 0$	KV 2	- " -	
3	$y_3 - \hat{T}_3 = 116 - 168 = -52$	KV 3	} TC	
4	$y_4 - \hat{T}_4 = 304 - 180 = 124$	KV 4		
5	$y_5 - \hat{T}_5 = 191 - 196 = 0$	KV 1		
6	$y_6 - \hat{T}_6 = 132 - 208 = -76$	KV 2		
7	$y_7 - \hat{T}_7 = 188 - 220 = -32$	KV 3		
8	$y_8 - \hat{T}_8 = 328 - 236 = 92$	KV 4		
9	$y_9 - \hat{T}_9 = 268 - 252 = 16$	KV 1		
10	$y_{10} - \hat{T}_{10} = 188 - 268 = -80$	KV 2	} TC	
11	$y_{11} - \hat{T}_{11} = 260 - * = 0$	KV 3		- " -
12	$y_{12} - \hat{T}_{12} = 384 - * = 0$	KV 4		- " -

b)

$$\bar{S}_{KV 1} = (0 + 0 + 16) / 3^2 = 16 / 9 = 5,333333333$$

$$\bar{S}_{KV 2} = (0 - 76 - 80) / 3^2 = -156 / 9 = -52$$

$$\bar{S}_{KV 3} = (-52 - 32 + 0) / 3^2 = -84 / 9 = -28$$

$$\bar{S}_{KV 4} = (124 + 92 + 0) / 3^2 = 216 / 9 = 72$$

Fortsättning b → nästa sida

	KV 1	KV 2	KV 3	KV 4	$\Sigma$
$\bar{S}_j$	5,3333	-52	-28	72	-2,6667
$S_j^+$	5,999975	-51,333325	-27,333325	72,666675	0

Rätt ide, fel siffror in

$$\frac{\sum \bar{S}_i}{p} = \frac{-2,6667}{4} = -0,666675$$

$$S_j^+ = \bar{S}_j - \left( \frac{\sum \bar{S}_i}{p} \right)$$

$$S_1^+ = 5,3333 - (-0,666675) = 5,3333 + 0,666675 = 5,999975$$

$$S_2^+ = -52 - (-0,666675) = -52 + 0,666675 = -51,333325$$

$$S_3^+ = -28 - (-0,666675) = -28 + 0,666675 = -27,333325$$

$$S_4^+ = 72 - (-0,666675) = 72 + 0,666675 = 72,666675$$

$\bar{S}_j$  = säsongindex  
 $S_j^+$  = justerade säsongindex

~~HA~~