

F9 - Multipel linjär regression

Statistisk översiktscurs

Ulf Högnäs

Statistiska institutionen
Stockholms universitet

April 9, 2025



Stockholm
University

- 1 Dummyvariabler
- 2 Multipel linjär regression
- 3 Att välja modell
- 4 Case study: Houses for sale
- 5 Modellens antaganden

Dummyvariabler

Enkel linjär regression

```
library(openintro)
loans <- loans_full_schema
View(loans)
table(loans$public_record_bankrupt)
# Ny variabel, 1 = minst en konkurs, 0 = inga konkurser
loans$bankruptcy <- as.numeric(loans$public_record_bankrupt>0)
# Skatta en linjär modell
model_bankrupt <- lm(interest_rate ~ bankruptcy, data = loans)
summary(model_bankrupt)
```

Dummyvariabel

Bankruptcy är ett exempel på en **dummyvariabel**


1	minst en konkurs
0	inga konkurser

```
Call:
lm(formula = interest_rate ~ bankruptcy, data = loans)

Residuals:
    Min       1Q   Median       3Q      Max
-7.7648 -3.6448 -0.4548  2.7120 18.6020

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  12.3380     0.0533  231.490 < 2e-16 ***
bankruptcy    0.7368     0.1529   4.819 1.47e-06 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 4.996 on 9998 degrees of freedom
Multiple R-squared:  0.002317, Adjusted R-squared:  0.002217
F-statistic: 23.22 on 1 and 9998 DF, p-value: 1.467e-06
```



Flera “levels” med dummyvariabler

- Många kategoriska variabler har fler än två kategorier
- Exempel: `verified_income`

Not Verified	Source Verified	Verified
3594	4116	2290

- `verified_income` har tre “levels” i R
- Vi skattar en modell ...

```
table(loans$verified_income)
model_verified <- lm(interest_rate ~ verified_income, data = loans)
summary(model_verified)
```

Dropped level

```
> model_verified <- lm(interest_rate ~ verified_income, data = loans)
> summary(model_verified)
```

Call:

```
lm(formula = interest_rate ~ verified_income, data = loans)
```

Residuals:

Min	1Q	Median	3Q	Max
-9.0437	-3.7495	-0.6795	2.5345	19.6905

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	11.09946	0.08091	137.18	<2e-16 ***
verified_incomeSource Verified	1.41602	0.11074	12.79	<2e-16 ***
verified_incomeVerified	3.25429	0.12970	25.09	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 4.851 on 9997 degrees of freedom

Multiple R-squared: 0.05945, Adjusted R-squared: 0.05926

F-statistic: 315.9 on 2 and 9997 DF, p-value: < 2.2e-16

Vad hände med kategorin “not verified”?

Base Category - den osynliga kategorin

- Tre alternativ för varje observation
 - 1 `verified_incomeSource Verified = 1`
`verified_incomeVerified = 0`
 - 2 `verified_incomeSource Verified = 0`
`verified_incomeVerified = 1`
 - 3 `verified_incomeSource Verified = 0`
`verified_incomeVerified = 0`
- Alternativ 3 betyder ingen av dessa två, d.v.s. “not verified”
- Denna kategori har blivit **base category**
- I denna modell är den skattade räntan för “not verified” lika med interceptet, dvs. 11.1%[†]
- Varför är räntan lägst för denna grupp?

[†]Beräkna den skattade räntan för resterande grupper. Lösning på s. 139 i boken.

Multipel linjär regression

Multipel linjär regression

- Vi antar att det finns ett linjärt samband mellan responsvariabeln och flera förklaringsvariabler
- Vi antar också att det finns variation ε som inte förklaras av modellen
- $y = \beta_0 + \beta_1 \cdot x_1 + \dots + \beta_k \cdot x_k + \varepsilon$
- Från den skattade modellen kan vi få prediktioner

$$\hat{y} = b_0 + b_1 \cdot x_1 + \dots + b_k \cdot x_k$$

Roligt att veta

- Istället för att anpassa en linje i 2D så anpassar vi ett **hyperplane** i ett rum med högre dimensioner
- man kan inte rita dimensioner högre än tre, men matten funkar ändå

Exempel: utlåningsräntor

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	1.893839	0.210245	9.008	< 2e-16	***
verified_incomeSource Verified	0.997468	0.099187	10.056	< 2e-16	***
verified_incomeVerified	2.563168	0.117184	21.873	< 2e-16	***
debt_to_income	0.021832	0.002937	7.434	1.14e-13	***
credit_util	4.896988	0.161887	30.249	< 2e-16	***
bankruptcy	0.391105	0.132286	2.957	0.00312	**
term	0.153388	0.003944	38.889	< 2e-16	***
credit_checks	0.228321	0.018242	12.516	< 2e-16	***
issue_monthJan-2018	0.045510	0.108034	0.421	0.67358	
issue_monthMar-2018	-0.041624	0.106545	-0.391	0.69605	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 4.3 on 9964 degrees of freedom

(24 observations deleted due to missingness)

Multiple R-squared: 0.2604, Adjusted R-squared: 0.2597

F-statistic: 389.7 on 9 and 9964 DF, p-value: < 2.2e-16

En modell med flera förklaringsvariabler

Att tolka koefficienter, ceteris paribus

Vad betyder det att koefficienten för bankruptcy är 0.39?

- Jämför två kunder, Madison och Harper
 - Madison har aldrig gått igenom en konkurs
 - Harper har gått igenom (minst) en konkurs
 - Allt annat i modellen är lika för Madison och Harper
 - **Ceteris paribus** ("allt annat hålls konstant")
- I så fall är den skattade räntan 0.39 procentenheter högre för Harper än för Madison

Uppgift

Tolka koefficienten för `verified_incomeSource Verified` (den är 0.997).

Att välja modell

Förklaringsgrad (R^2)

I föreläsning 8 ingick en intuitiv beskrivning av R^2 . Här är den matematiska definitionen.

R^2

Coefficient of Determination (sv. förklaringsgrad)

$$\begin{aligned} R^2 &= 1 - \frac{\text{Variationen i residualerna}}{\text{Variationen i utfallet}} \\ &= 1 - \frac{\text{Var}(e)}{\text{Var}(y)} \end{aligned}$$

R^2 mäter hur stor andel av variationen i utfallet som förklaras av modellen.

Justerad förklaringsgrad (R_{adj}^2)

R_{adj}^2 - Adjusted Coefficient of Determination

Den justerade förklaringsgraden tar hänsyn till antalet variabler i modellen och beräknas som

$$\begin{aligned} R_{adj}^2 &= 1 - \frac{s_{\text{residualer}}^2 / (n - k - 1)}{s_{\text{utfall}}^2 / (n - 1)} \\ &= 1 - \frac{s_{\text{residualer}}^2}{s_{\text{utfall}}^2} \cdot \frac{n - 1}{n - k - 1} \end{aligned}$$

- n är antalet observationer som används för att anpassa modellen.
- k är antalet förklarande variabler i modellen.

Vad händer om antalet förklarande variabler ökar, utan att residualernas storlek minskas nämnvärt?

Backward elimination

Den förra modellen hade $R^2 = 0.2604$ respektive $R^2_{adj} = 0.2597$

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	1.896283	0.198294	9.563	< 2e-16 ***
verified_incomeSource Verified	0.996255	0.099139	10.049	< 2e-16 ***
verified_incomeVerified	2.560756	0.117131	21.862	< 2e-16 ***
debt_to_income	0.021852	0.002937	7.441	1.08e-13 ***
credit_util	4.896475	0.161845	30.254	< 2e-16 ***
bankrupcy	0.391645	0.132272	2.961	0.00307 **
term	0.153356	0.003943	38.893	< 2e-16 ***
credit_checks	0.228409	0.018241	12.522	< 2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 4.3 on 9966 degrees of freedom

(24 observations deleted due to missingness)

Multiple R-squared: 0.2603, Adjusted R-squared: 0.2598

Vi tog bort issue_month. Vad hände med R^2 respektive R^2_{adj} ?


Ett sätt att välja vilka förklaringsvariabler som ska vara med är

Backward elimination

- 1 Skatta en stor modell med många eller alla förklaringsvariabler
- 2 Ta bort förklaringsvariabeln med sämst p-värde och skatta modellen igen
- 3 Om R^2_{adj} ökade, upprepa steg 2
- 4 Om R^2_{adj} minskade, lägg tillbaka variabeln och prova att ta bort en annan variabel
- 5 Du är klar när du inte kan förbättra R^2_{adj}

Case study: Houses for sale

Duke Forest




Duke Forest, Durham, NC. Zillow.com.



Det första huset i duke_forest från openintro. Zillow.com.

Korrelationsplottar



Några förklaringsvariabler vs pris

Första modellen

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	-2.911e+06	1.788e+06	-1.628	0.10703	
bed	-1.369e+04	2.593e+04	-0.528	0.59874	
bath	4.108e+04	2.466e+04	1.666	0.09928	.
area	1.021e+02	2.313e+01	4.416	2.79e-05	***
year_built	1.459e+03	9.140e+02	1.597	0.11385	
coolingcentral	8.407e+04	3.034e+04	2.771	0.00679	**
lot	3.561e+05	7.594e+04	4.690	9.70e-06	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 145100 on 90 degrees of freedom

Första modellen, från boken

Table 10.4: Summary of least squares fit for price on multiple predictor variables.

term	estimate	std.error	statistic	p.value
(Intercept)	-2,910,715	1,787,934	-1.63	0.107
area	102	23	4.42	<0.0001
bed	-13,692	25,928	-0.53	0.5987
bath	41,076	24,662	1.67	0.0993
year_built	1,459	914	1.60	0.1139
coolingcentral	84,065	30,338	2.77	0.0068
lot	356,141	75,940	4.69	<0.0001

Adjusted R-sq = 0.5896

df = 90

Från s. 172

Uppgift

- 1 Tolka koefficienten för bed. Varför tror ni att den är negativ?
- 2 Vilken variabel bör vi prova att ta bort i vår backward elimination?



Observation 18.



Observation 83.

Andra modellen, vi eliminerade bed

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	-2.953e+06	1.779e+06	-1.660	0.10043	
bath	3.623e+04	2.280e+04	1.589	0.11552	
area	9.906e+01	2.230e+01	4.443	2.49e-05	***
year_built	1.466e+03	9.102e+02	1.611	0.11068	
coolingcentral	8.386e+04	3.022e+04	2.775	0.00669	**
lot	3.571e+05	7.562e+04	4.723	8.41e-06	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 144600 on 91 degrees of freedom

(1 observation deleted due to missingness)

Multiple R-squared: 0.6141, Adjusted R-squared: 0.5929

Förbättrades modellen när vi eliminerade bed?

Multikollinearitet

Multikollinearitet uppstår när de förklarande variablerna är starkt korrelerade med varandra. När variablerna i modellen är alltför inbördes korrelerade kan det bli svårt att tolka regressionskoefficienterna.

Är det den arean eller antalet sovrum som avgör priset? Modellen kan inte hålla isär effekterna.

Tredje modellen, vi eliminerade bath

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	-3.706e+06	1.729e+06	-2.143	0.03473	*
area	1.209e+02	1.772e+01	6.820	9.39e-10	***
year_built	1.870e+03	8.813e+02	2.122	0.03653	*
coolingcentral	9.221e+04	3.000e+04	3.074	0.00278	**
lot	3.693e+05	7.585e+04	4.868	4.65e-06	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 145800 on 92 degrees of freedom

(1 observation deleted due to missingness)

Multiple R-squared: 0.6034, Adjusted R-squared: 0.5861

Förbättrades modellen när vi eliminerade bath?

Winner: Andra modellen

Uppgift

Beräkna det skattade värdet för ett hus som

- har area 1661 sq ft
- har tre sovrum^a
- har två badrum
- är byggt 1941
- inte har central cooling
- har en 0.54 acre lot

^aVad ska vi göra med denna information?

term	estimate
(Intercept)	-2,952,641
area	99
bath	36,228
year_built	1,466
coolingcentral	83,856
lot	357,119
<i>Adjusted R-sq = 0.5929</i>	
<i>df = 91</i>	

Koefficienter för den andra modellen

Beräkna Residualen för observation 69

Uppgift

Förklaringsvariablernas värden på förra bilden är hämtade från rad 69, 2618 Pickett Rd, Durham, NC 27705. Husets försäljningspris var \$412,500. Vad blir residualen för denna observation?



Observation 69.

Modellens antaganden

Kort om modellens antaganden

Regression vilar på några antaganden som måste stämma någorlunda för att modellen ska fungera. Se även bild 15 från föreläsning 8.

Antaganden för linjär regression


- 1 **Linjära samband** Sambandet mellan varje förklarande variabel och responsvariabeln är linjärt.
- 2 **Oberoende observationer** Observationerna är oberoende av varandra.
- 3 **Homoskedasticitet** Variansen i residualerna är konstant
- 4 **Normalfördelade residualer** Residualerna är normalfördelade.
- 5 **Ingen multikollinaritet** De förklarande variablerna är inte starkt korrelerade med varandra.

Exempel. Antagande 3: Homoskedasticitet

För att undersöka om homoskedasticitet är ett rimligt antagande kan man plotta skattade värden (x-axel) mot residualerna (y-axel)




OK...? Inte det värsta jag har sett



Katastrof


Exempel. Antagande 4: Normalfördelade residualer



Är antagandet om normalfördelade residualer ungefär uppfyllt?

- Om modellens antaganden inte alls är uppfyllda kan vi inte lita på prediktioner och inferens
- Vi kan hitta resultat som egentligen är felaktiga
- Lösningen kan vara en **transformation** av någon variabel
- En vanlig lösning är att ta logaritmen av varje y-värde (responsvariabeln) och sedan skatta modellen igen
 - 1 Transfomera responsvariabeln med `log()`
 - 2 Skatta modellen
 - 3 Stoppa in varje prediktion i `exp()` för att få värden som går att förstå

Residualer efter en framgångsrik transformation



Detta ser bra ut