

Logistisk regression

Susanne Rosthøj

26. oktober 2020

Outline

Outcome er *binært* (0/1, ja/nej eller case/kontrol).

- ▶ Tabeller
- ▶ Risk, odds og odds-ratio
- ▶ Simpel logistisk regression:
 - ▶ Binær
 - ▶ Kvantitativ
 - ▶ En binær og en kvantitativ
 - ▶ Interaktion
 - ▶ Flere kovariater
- ▶ Modelkontrol
 - ▶ Diagnostics
- ▶ Prædiktion

Typer af outcome

- ▶ Kvantitativ - *den generelle lineære model*
- ▶ **Binær** - *logistisk regression*
- ▶ *Ordinal - proportional odds regression*
- ▶ Tællel - *Poisson regression*
- ▶ Levetid - *Cox regression*

Eksempler på binære outcomes

- ▶ Farveblindhed
- ▶ Komplikationer ved operation
- ▶ Udskrivning af astmapatienter efter første undersøgelse
- ▶ Astma
- ▶ Vitamin D-deficiens

Prostata kræft

380 patienter, variable målt ved baseline eksamination.

Outcome:

spredning Tumor er trængt igennem prostatakapslen
(0/1, 1="spredning")

Hvordan afhænger risikoen for spredning af

Forklarende variable:

<i>psa</i>	Prostatic Specific Antigen Value mg/ml
<i>involvering</i>	Kapsel involvering ved rektal eksploration (0/1, 1="involvering")
<i>knude</i>	Knudes placering på lap ("ingen", "venstre", "højre", "begge")
<i>alder65</i>	Under / over 65 år ("Under"/"Over")
<i>gleason</i>	Gleason score, 0-10.

Kan vi ud fra disse variable prædiktere spredning?

Involvering og spredning

		Spredning				
		0		1		total
Involvering	0: nej	217	(64.0)	122	(36.0)	339
	1: ja	10	(24.4)	31	(75.6)	41
total		227		153		380

Er risikoen for spredning den samme uanset involvering eller ej?

p_{uden} Risiko for patienter *uden* involvering

p_{med} Risiko for patienter *med* involvering

Hypotese: $p_{uden} = p_{med}$

Test for uafhængighed

Hypotese: $p_{uden} = p_{med}$ testes med

- ▶ Chi-i-anden test (χ^2 -test)
 - når tabellen ikke er 'for tynd' (forventede værdier ≥ 5)
- ▶ Fishers eksakte test
 - som altid kan bruges

Disse er *test for uafhængighed* mellem kovariat (involvering) og outcome (spredning)

Her er $p < .0001$ ($\chi^2 = 23.9$, $df=1$) og vi konkluderer at risikoen for spredning er *forskellig* for patienter med og uden involvering.

Kvantificering af effekten I

Risikodifferens:

$$p_{med} - p_{uden} = 75.6 - 36.0 = 39.6$$

*Der er 39.6 procent**point** flere patienter med involvering der får spredning end patienter uden (95% CI 24.2 til 55.1)*

Kvantificering af effekten II

Relativ risiko:

$$\frac{p_{med}}{p_{uden}} = \frac{75.6}{36.0} = 2.10$$

Risikoen for spredning er 2.1 gange større for patienter med involvering ifht patienter uden involvering (95% CI 1.68 til 2.63)

Patienter med involvering har 110% større risiko for spredning end patienter uden (95% CI 68 til 163%)

Kvantificering af effekten III

Odds for patienter med involvering:

$$odds_{med} = \frac{p_{med}}{1 - p_{med}} = \frac{31/41}{1 - 31/41} = \frac{31}{10} = 3.1$$

Odds for patienter uden involvering:

$$odds_{uden} = \frac{p_{uden}}{1 - p_{uden}} = \frac{122}{217} = 0.56$$

Odds ratio:

$$OR = \frac{odds_{med}}{odds_{uden}} = \frac{3.1}{0.56} = 5.51$$

Odds for spredning er 5.5 gange større for patienter med involvering end for patienter uden (95% CI 2.61 til 11.63)

Formålet med logistisk regression

For et **binært outcome**, e.g.

$$Y_i = \begin{cases} 1 & \text{hvis patient } i \text{ havde spredning} \\ 0 & \text{hvis patient } i \text{ ikke havde spredning} \end{cases}$$


at beskrive sammenhængen med forklarende variable for patient i .

I logistisk regression formulerer vi modeller for **log-odds**:

$$\log(\text{odds}_i) = \log\left(\frac{p_i}{1 - p_i}\right) = \text{logit}(p_i)$$

som vi kalder for logit-funktionen.

Sandsynlighed og log-odds



Den logistiske regressionsmodel

Kovariat:

$$\text{involvering}_i = \begin{cases} 0 & \text{hvis patient } i \text{ uden involvering} \\ 1 & \text{hvis patient } i \text{ med involvering} \end{cases}$$

Model:

$$\begin{aligned} \log\left(\frac{p_i}{1-p_i}\right) &= a + b \cdot \text{involvering}_i = \begin{cases} a & i \text{ uden involvering} \\ a + b & i \text{ involvering} \end{cases} \\ &= \begin{cases} \log\left(\frac{122}{217}\right) \\ \log\left(\frac{31}{10}\right) \end{cases} = \begin{cases} -0.58 \\ 1.13 \end{cases} \\ &= \begin{cases} -0.58 \\ -0.58 + (1.13 + 0.58) \end{cases} = \begin{cases} -0.58 \\ -0.58 + 1.71 \end{cases} \end{aligned}$$

Forskellen i **log-odds** mellem patienter med og uden involvering er $b=1.71$ (!)

OR fra logistisk regression

$$\log\left(\frac{p_i}{1-p_i}\right) = a + b \cdot \text{involvering}_i = \begin{cases} a & i \text{ uden involvering} \\ a + b & i \text{ med involvering} \end{cases}$$

Effekten af involvering er givet ved b :

$$\begin{aligned} b &= (a + b) - a \\ &= \log(\text{odds med involvering}) - \log(\text{odds uden involvering}) \\ &= \log\left(\frac{\text{odds med involvering}}{\text{odds uden involvering}}\right) = \log(\text{OR}) \end{aligned}$$

ie.

$$\exp(b) = \text{OR} = \exp(1.71) = 5.51$$

Hvad er OR for ingen involvering vs involvering?

Logistisk regression i R / SAS

Logistisk regression hører under klassen af **G**eneraliserede **L**ineære **M**odeller (GLM - ikke at forveksle med *Generel* LM)

R-kode:

```
glm1 <- glm( spredning ~ involvering, data=d,  
             family = 'binomial')  
summary( glm1 )
```

SAS:

```
proc logistic data = d;  
  class involvering (ref='0') / param=glm;  
  model spredning(event='1') = involvering;  
run;
```

Logistisk regression i SPSS

Analyze -> Generalized Linear Models

5 faner skal udfyldes:

Type of Model: Vælg Binary Logistic (under Binary Response)

Response: Sæt spredning som Dependent Variable. Under Reference category vælges First (lowest value), således at spredning=1 vurderes mod spredning=0 (dvs risikoen for spredning i stedet for risikoen for ikke at have spredning)

Predictors: Her sættes kvalitative (faktorer, her involvering) i Factors (i Options afkrydse descending under Category Order for Factors for at få 0 som reference). Kvantitative sættes i Covariates.

Model: Som GLM

Statistics: Afkryds Include exponential parameter estimates (under Print)

Output i R - I

```
glm1 <- glm( spredning ~ involvering, data=d,  
             family = 'binomial')  
summary( glm1 )
```

Call:

```
glm(formula = spredning ~ involvering, family = "binomial", data = d)
```

Deviance Residuals:

	Min	1Q	Median	3Q	Max
	-1.6799	-0.9446	-0.9446	1.4297	1.4297

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-0.5759	0.1132	-5.089	0.00000036 ***
involvering	1.7073	0.3809	4.483	0.00000738 ***

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

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 512.29 on 379 degrees of freedom
Residual deviance: 488.53 on 378 degrees of freedom
AIC: 492.53

Number of Fisher Scoring iterations: 4

Output i R - II

```
coef( glm1 )
```

```
(Intercept) involvering  
-0.5758763    1.7072784
```

```
exp( coef(glm1) )
```

```
(Intercept) involvering  
0.562212    5.513934
```

```
exp( confint.default(glm1) )
```

```
                2.5 %    97.5 %  
(Intercept) 0.4503797 0.701813  
involvering 2.6137465 11.632143
```

Output i SAS

Analysis of Maximum Likelihood Estimates

Parameter	DF	Estimate	Standard Error	Wald Chi-Square	Pr > ChiSq
Intercept	1	-0.5759	0.1132	25.8987	<.0001
involvering	1 1	1.7073	0.3809	20.0933	<.0001
involvering	0 0	0	.	.	.

Odds Ratio Estimates

Effect	Point Estimate	95% Wald Confidence Limits
involvering 1 vs 0	5.514	2.614 11.632

Output - SPSS


Fylder alt for meget til at det kan være her ...

Under blokken med 'Parameter Estimates' aflæses

- ▶ a og b i første søjle (B)
- ▶ OR i 3. sidste søjle ($\text{Exp}(B)$)
- ▶ CI i de to sidste søjler
- ▶ p-værdi i 4. sidste søjle

Kvantitativ kovariat

Lineær regression går ikke:



Logistisk regression med en kvantitativ kovariat

Model for log-odds er lineær: $\log\left(\frac{p_i}{1-p_i}\right) = a + b \cdot \text{psa}_i$

Sammenlign to patienter med en forskel på 1 $\mu\text{g/L}$ PSA, feks 51 vs 50:

$$\text{OR} = \frac{\text{odds PSA} = 51}{\text{odds PSA} = 50}$$

$$\log(\text{OR}) = \log(\text{odds PSA} = 51) - \log(\text{odds PSA} = 50) \quad (1)$$


$$= (a + 51 \cdot b) - (a + 50 \cdot b) \quad (2)$$

$$= b \quad (3)$$

i.e.


$$\text{OR} = \exp(b) = \exp(0.05) = 1.05.$$

Plot på logit-skala



Prædikterede sandsynligheder

$$p(x) = \frac{\exp(a + b \cdot x)}{1 + \exp(a + b \cdot x)}$$



Øvelse: Rapportering pr 10 enheder

$$\log\left(\frac{p_i}{1-p_i}\right) = a + b \cdot \text{psa}_i, \quad b = 0.0502$$
$$OR = \exp(0.0502) = 1.0513$$

Vi vil næppe rapportere effekten af PSA pr 1 enhed $\mu\text{g/L}$.

Hvad er effekten af PSA pr 10 $\mu\text{g/L}$?

Man finder en OR på:

1. 1.50
2. 1.65
3. 1.89
4. 10.51

Modelkontrol

Vi har antaget at effekten af PSA lineær (på logit-skala). Er det rimeligt?

Numerisk modelkontrol:

- ▶ **Overall goodness of fit:** Hosmer-Lemeshow test
- ▶ **Linearitet:** Lineære splines, tilføj logaritmeret eller kvadreret kovariat
- ▶ **Grafisk modelkontrol:** Residualplot
- ▶ **Diagnostics:** Cook, dfbetas

Overall test for Goodness-of-fit

Hosmer-Lemeshow goodness-of-fit test:

- ▶ Observationerne inddeles i 10 ca. lige store grupper, baseret på stigende prædikeret sandsynlighed for gennemtræning
- ▶ I hver gruppe sammenlignes observerede og forventede antal af spredninger og størrelserne

$$\frac{(\text{observeret antal} - N\hat{p})^2}{N\hat{p}(1 - \hat{p})}$$

sammenlægges til en approksimativ χ^2 -teststørrelse med 8 frihedsgrader (antal grupper minus 2)

Test af goodness-of-fit

	y0	y1	yhat0	yhat1
[0.25,0.272]	36	4	29.489598	10.51040
(0.272,0.291]	25	11	25.851318	10.14868
(0.291,0.305]	28	10	26.690339	11.30966
(0.305,0.322]	25	15	27.435075	12.56493
(0.322,0.337]	20	16	24.114498	11.88550
(0.337,0.363]	34	10	28.603123	15.39688
(0.363,0.395]	21	12	20.447832	12.55217
(0.395,0.474]	15	22	20.927518	16.07248
(0.474,0.635]	16	22	17.595647	20.40435
(0.635,0.997]	7	31	5.845053	32.15495

Her finder vi $\chi^2 = 15.95$ og dermed $p=0.04$. Dermed halter modellen lidt.

Overall test af goodness-of-fit i praksis

Vi har kun én forklarende variabel. Hosmer-Lemeshow testet kan også benyttes på multivariable modeller.

I tilfælde af sparsomme data kan inddelingen have en del indflydelse på testet, dvs. det er meget **ustabilt**. SAS giver her f.eks. pga anden inddeling $p=0.001$...

Desuden kan det ændre sig, hvis man skifter til at se på det modsatte outcome altså spredning="0" (i R er $p=0.09$ vs $p=0.04$).

Residualplot

Pearson residualer

$$res_i = \frac{y_i - \hat{p}_i}{\sqrt{\hat{p}_i \cdot (1 - \hat{p}_i)}}$$


plottes vs

- ▶ kovariater
- ▶ fittede værdier



for at se efter krumninger som tegn på manglende linearitet.

Residualplot

Bliver skøre at se på ...



Diagnostics plots



PSA som lineær spline

Tærskelværdier bestemmes ud fra kvartiler for PSA blandt 'cases':

25%: 7.4

50%: 13.2

75%: 26.0

Splinevariable:


$$\text{psa_7_4} = \begin{cases} \text{psa} - 7.4 & \text{psa} > 7.4 \\ 0 & \text{psa} \leq 7.4 \end{cases}$$

Tilsvarende defineres psa_13_2 og psa_26

Output

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-2.0697	0.4651	-4.4500	0.0000
psa	0.2178	0.0817	2.6661	0.0077
psa_7_4	-0.2209	0.1352	-1.6336	0.1023
psa_13_2	0.0887	0.1035	0.8568	0.3915
psa_26	-0.0619	0.0498	-1.2444	0.2134

Effekt af PSA som lineær spline



Test af linearitet: $H_0: \text{psa_7_4}=\text{psa_13_2}=\text{psa_26}=0$ giver $p=0.057$ (df=3)

Rapportering af splinemodellen

Med en lineær spline afhænger OR af PSA-værdierne:


I intervallerne er

PSA	log-odds bidrag	OR	CI
< 7.2:	.2178	1.24	1.06-1.48
7.2-13.2:	.2178-.2209	1.00	0.86-1.15
13.2-26.0:	.2178 -.2209+.0887	1.09	1.01-1.18
> 26.0:	.2178-.2209+.0887-.0619	1.02	1.00-1.05

pr 1 $\mu\text{g/L}$ PSA.

Prædikterede sandsynligheder

Hosmer-Lemeshow $p=0.50$.



Test for lineær effekt af $\log(\text{PSA})$

Definér ny variabel: $\log_2\text{psa} = \log_2(\text{PSA})$

Model:
$$\log\left(\frac{p_i}{1-p_i}\right) = a + b \cdot \text{psa}_i + c \cdot \log_2\text{psa}_i$$

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-2.0707	0.4119	-5.0270	0.0000
psa	0.0147	0.0138	1.0598	0.2892
log2psa	0.4459	0.1651	2.7010	0.0069

Med $\log_2(\text{PSA})$ i modellen bliver PSA overflødig, $p=0.29$

Model med log(PSA)

$$\text{Model:} \quad \log\left(\frac{p_i}{1-p_i}\right) = a + c \cdot \log_2(\text{psa}_i)$$

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-2.3756	0.3256	-7.2969	0
log2psa	0.6020	0.0909	6.6232	0


Effekten af $\log_2(\text{PSA})$ er beskrevet ved $c = 0.602$ (95 %CI 0.424 til 0.780)

Dvs ved en **fordobling** af PSA ...

... er $OR = \exp(0.602) = 1.83$ (95% CI 1.53 til 2.18)


... øges odds for spredning med 83% (95% CI 53 til 118%)

Effekt af $\log_2(\text{PSA})$ på logit-skala



Prædikterede sandsynligheder

Hosmer-Lemeshow $p=0.17$.



En kvalitativ og en kvantitativ kovariat

Model:

$$\begin{aligned}\log\left(\frac{p_i}{1-p_i}\right) &= a + b \cdot \text{involvering}_i + c \cdot \log_2(\text{psa}_i) \\ &= \begin{cases} a + c \cdot \log_2(\text{psa}_i) & \text{hvis } \text{involvering}_i = 0 \\ a + b + c \cdot \log_2(\text{psa}_i) & \text{hvis } \text{involvering}_i = 1 \end{cases}\end{aligned}$$

Hvad forventer vi sker med OR for involvering (ujusteret OR=5.51)?

Output

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-2.3242	0.3276	-7.0936	0.000
involvering	1.2530	0.4053	3.0914	0.002
log2psa	0.5487	0.0927	5.9163	0.000

For fastholdt PSA er $OR = \exp(1.25) = 3.50$ for involvering vs ingen involvering

For fastholdt involvering er $OR = \exp(0.55) = 1.73$ ved en fordobling af PSA

Fiktivt eksempel


Hvornår skal man justere?

Tænkt eksempel: Køn, kvantitativ kovariat X og binært outcome Y .

Både køn og X er prædiktive for Y , men der er **ingen** association mellem køn og X .


Dvs der er ingen confounding.

X vs køn




Tilbageblik på lineær regression

Her er Y kvantitativ:



Logistisk regression med / uden betydnende kovariat



Konsekvens af manglende kovariat

Mangler vi en vigtig prædiktor for outcome bliver OR i det samlede materiale (/ujusteret) *mindre* end i subgrupperne (/justeret).

Det skyldes (*teknisk!*) at logit-funktionen ikke er lineær og at vi ved udeladelse af kovariaten tager gennemsnit over *inhomogene* populationer.

Randomiserede studier:

- ▶ Vi har sjældent alle kovariater
- ▶ Er der strenge inklusionskriterier har vi en ret homogen population, og OR bliver formentligt stor
- ▶ Er der ingen inklusionskriterier har vi en ret inhomogen population, og OR bliver formentligt lille

Vi kan *ikke* direkte sammenligne OR'er, hvor vi ikke justerer for det samme!

Interaktion

Spredning vs Gleason:



	gleason	Antal	antal0	antal1	Andele	andel0	andel1
1	0		2	0		1.00	0.00
2	4		1	0		1.00	0.00
3	5		61	6		0.91	0.09
4	6		101	38		0.73	0.27
5	7		55	73		0.43	0.57
6	8		6	24		0.20	0.80
7	9		1	12		0.08	0.92

Har Gleason score lige stor betydning for 'unge' og 'ældre'?

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-6.8693	1.1711	-5.8659	0.0000
alder65Under	-5.3611	2.3484	-2.2829	0.0224
gleason	0.9906	0.1759	5.6303	0.0000
alder65Under:gleason	0.8623	0.3619	2.3828	0.0172

Muligvis - vi har en p -værdi på 0.02.

Prædikterede sandsynligheder



Interaktionsmodeller i R / SAS / SPSS

Syntaks i R

```
glm( spredning ~ alder65*gleason, data=d, family='binomial')  
glm( spredning ~ alder65+alder65:gleason, data=d, family='binomial')
```

Syntaks i SAS (proc logistic)

```
proc logistic data=d;  
  class alder65 (ref='Under') / param=glm;  
  model spredning(event='1') = alder65 gleason alder65*gleason;  
  oddsratio gleason / at ( alder65="Under" "Over");  
run;
```

SPSS

Når modellen bygges tilføjes alder65 og interaktionen mellem alder65 og gleason

Rapportering af modellen

Vi påstår, at der er en interaktion mellem aldersgruppe og gleason score, $p=0.02$

Vi må derfor rapportere effekten af gleason for hver aldersgruppe.
Her finder vi

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-6.8693	1.1711	-5.8659	0.0000
alder65Under	-5.3611	2.3484	-2.2829	0.0224
alder65Over:gleason	0.9906	0.1759	5.6303	0.0000
alder65Under:gleason	1.8529	0.3162	5.8595	0.0000

For de yngre (≤ 65 år) er $OR = \exp(1.85) = 6.37$ pr 1 i gleason score, 95% CI 3.43 til 11.85.

For de ældre (> 65 år) er $OR = \exp(0.99) = 2.69$ pr 1 i gleason score, 95% CI 1.91 til 3.80.

En multivariabel model

Med udgangspunkt i de forrige modeller kan vi formulere en model med alle variable, f.eks.

	Estimate	Pr(> z)	OR	lower	upper
(Intercept)	-6.834	0.000	0.00	0.00	0.00
involvering	0.618	0.174	1.85	0.76	0.76
log2psa	0.316	0.003	1.37	1.11	1.11
alder65Under	-5.031	0.034	0.01	0.00	0.00
gleason	0.690	0.000	1.99	1.38	1.38
knudeBegge	1.390	0.002	4.01	1.67	1.67
knudeHoejre	1.463	0.000	4.32	2.08	2.08
knudeVenstre	0.721	0.044	2.06	1.02	1.02
alder65Under:gleason	0.796	0.029	2.22	1.08	1.08

Hosmer-Lemeshow goodness-of-fit $p=0.25$

Fortolkning:

Ved en fordobling af PSA øges odds for spredning med 37% ($OR=\exp(0.32)=1.37$) for fastholdt involvering, alder, gleason og knudeplacering.

...

Kan vi prædiktere?

$$\hat{p}_i = \frac{\exp(-6.83 + 0.62 \cdot \text{involvering} + 0.32 \cdot \log_2\text{psa} + \dots)}{1 + \exp(-6.83 + 0.62 \cdot \text{involvering} + 0.32 \cdot \log_2\text{psa} + \dots)}$$

Vi kan vælge en tærskelværdi, f.eks. $p=0.5$, og definere:

person i som **case** hvis $\hat{p}_i > 0.5$

person i som **kontrol** hvis $\hat{p}_i \leq 0.5$

Prædiktion

Spredning case kontrol

0 36 191

1 103 50


Sensitivitet: $\frac{103}{103+50}=0.67$

Specificitet: $\frac{191}{191+36}=0.84$

Andel korrekt klassificeret: $\frac{191+103}{380}=0.77$

ROC kurve


Receiver Operating Characteristics kurve:



Optimal tærskelværdi

Closest top-left: 0.412

Youden: 0.323



AUC

Arealet under kurven (AUC) bruges som et mål for, hvor godt vi kan prædiktere:

- 1 Perfekt prædiktions!
- 0.5 Svarer til at vi kaster en mønt
- 0 Fuldstændig forkert prædiktions

Her er $AUC=0.83$ (95% CI 0.79-0.87)

ADVARSEL: Vi kan *ikke* evaluere hvor godt en model prædikerer på baggrund af de data, modellen er baseret på. AUC skal derfor korrigeres for "*optimisme*".

- ▶ Training og validation sets
- ▶ Bootstrap
- ▶ Shrinkage (nedskalering) af koefficienterne fra modellen

Forslag til ekstra litteratur

Om brug af residualer og diagnostics:

Zhang, Z. Residuals and regression diagnostics: focusing on logistic regression (2016) *Annals of Translational Medicine*
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4885900/>
(baseret på R-kode)

Korrektion for optimisme:

Moons et al. Risk prediction models: I. Development, internal validation, and assessing the incremental value of a new (bio)marker (2012) *Heart*