


# Kapittel 14 Logistisk regresjon

# Logistisk regresjon


- Logistisk regresjon med én forklaringsvariabel
  - Odds og odds-ratio
  - Tolkning av koeffisienter
  - Inferens – konfidensintervaller og Wald-test
- Multippel logistisk regresjon

## 14.1 Logistisk regresjon

- I kapittel 10 og 11 (lineær regresjon) hadde vi



- I kapittel 14 (logistisk regresjon) har vi



$$y = \begin{cases} 1 & \text{"suksess" (f.eks. syk, kort hale, er på instagram, olje!)} \\ 0 & \text{ellers (f.eks. frisk, lang hale, er ikke på insta, tørr)} \end{cases}$$

Vi har data  $(x_1, y_1), \dots, (x_n, y_n)$ .

Her er  $y_i$  en binær respons (0 eller 1) for individ  $i$ ,  
og  $x_i$  er en forklaringsvariabel (binær eller kvantitativ).

Vi er interesserte i hvordan ‘suksess’-sannsynligheten  $P(y=1)$  påvirkes av  $x$ .

Vi lar suksess-sannsynligheten være en funksjon av  $x$ ,

$$p(x) = E(y | x) = P(y = 1 | x)$$

og ønsker en modell som beskriver forholdet mellom  $p(x)$  og  $x$

En mulig modell for  $p(x)$  kunne være en enkel lineær modell  $p(x) = \beta_0 + \beta_1 x$


Dette er en **additiv risiko-modell**, som kan brukes i enkelte situasjoner.

Husk at vi må ha  $0 \leq p(x) \leq 1$  for alle  $x$ , for at  $p(x)$  skal være en sannsynlighet for alle  $x$ .  
Vi kan ikke sikre oss mot at en lineær modell kan gi ulovlige verdier for  $p(x)$


Vi kan sikre lovlige verdier for  $p(x)$  ved å bruke en **logistisk regresjonsmodell** gitt ved

$$p(x) = \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 x)}$$


Dette gir en "S-formet" sammenheng mellom  $p(x)$  og  $x$



## Linear Regression




## Logistic Regression



$$p(x) = \beta_0 + \beta_1 x$$

$$p(x) = \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 x)}$$

Vi ser her kurven for  $p(x) = \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 x)}$   
plottet for noen ulike kombinasjoner av verdier for parameterne  $\beta_0$  og  $\beta_1$



# Tre ekvivalente måter å formulere den logistiske regresjonsmodellen på

Vi har sett på formelen for  $p(x)$ :

$$p(x) = \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 x)}$$

Logistisk regresjon kan også formuleres vha odds:

**Odds for suksess =  $p / (1-p)$**

$$\frac{p(x)}{1 - p(x)} = \exp(\beta_0 + \beta_1 x)$$

Læreboka vår formulerer modellen ved å si at log-odds følger en lineær modell

$$\log\left[\frac{p(x)}{1 - p(x)}\right] = \beta_0 + \beta_1 x$$

# Logistisk regresjon med en forklaringsvariabel

## LOGISTIC REGRESSION MODEL

The **statistical model for logistic regression** is

$$\log\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x$$

where  $p$  is a binomial proportion and  $x$  is the explanatory variable. The parameters of the logistic regression model are  $\beta_0$  and  $\beta_1$ .

*Merk: her skriver vi log for den naturlige logaritmen (også kalt ln)*

# Odds og odds-ratio eksempel

Tilfeldig utvalg på 1069 unge bestående av 537 kvinner og 532 menn

La  $p_k = P(\text{tilfeldig kvinne i denne aldersgruppen er Instagrambruker})$

La  $p_m = P(\text{tilfeldig mann i denne aldersgruppen er Instagrambruker})$

Andel kvinner i utvalget som er Instagrambrukere:  $\hat{p}_k = \frac{328}{537} = 0.6108$

Estimert odds Instagrambruker for kvinner:

$$\frac{\hat{p}_k}{1-\hat{p}_k} = \frac{0.6108}{1-0.6108} = 1.5694$$

Andel menn i utvalget som er Instagrambrukere:  $\hat{p}_m = \frac{234}{532} = 0.4398$

Estimert odds Instagrambruker for menn:

$$\frac{\hat{p}_m}{1-\hat{p}_m} = \frac{0.4398}{1-0.4398} = 0.7851$$

Estimert *odds-ratio* for kvinner i forhold til menn:

$$OR = \text{Odds}_{\text{kvinne}} / \text{Odds}_{\text{mann}} = 1.5694 / 0.7851 = 1.999$$

Omtrent dobbelt så stor odds for kvinner som for menn for å være Instagrambruker for disse utvalgene

# Odds-ratio: Ratioen mellom oddsene for to ulike verdier av forklaringsvariabelen

Hvis vi ser på to individer som har kovariater henholdsvis  $x + \Delta$  og  $x$ , blir odds-ratioen mellom dem (OR):

$$\frac{p(x + \Delta)/[1 - p(x + \Delta)]}{p(x)/[1 - p(x)]} = \frac{\exp(\beta_0 + \beta_1(x + \Delta))}{\exp(\beta_0 + \beta_1 x)} = \exp(\beta_1 \Delta)$$

## Tolkning av regresjonskoeffisienter

Når  $\Delta = 1$ , ser vi at  $e^{\beta_1}$  er **odds-ratioen** som tilsvarer en enhets økning i verdien av forklaringsvariabelen.

For eksempel, hvis vi lar  $x=1$  for kvinner og  $x=0$  for menn blant instagrambrukerne, er odds-ratioen for kvinner sammenligna med menn  $e^{\beta_1}$

# Eksempel: WCGS er en stor epidemiologisk studie designet for å studere risikofaktorer for hjertesykdom blant middelaldrende menn.

Mennene ble fulgt opp i 10 år, og for hver mann ble det registrert om han utviklet hjertesykdom ( $y = 1$ ) eller ikke ( $y = 0$ ) i løpet av perioden.

Hvordan påvirker mennenes alder (ved oppstart av studien) risikoen (sannsynligheten) for å utvikle hjertesykdom?

Sammendrag av data

Aldersgr. v/ oppstart	35-40	41-45	46-50	51-55	56-60
Totalantall	543	1091	750	528	242
Antall syke	31	55	70	65	36
Andel syke	5.7 %	5.0 %	9.3 %	12.3 %	14.9 %



# La oss analysere dataene fra WCGS i R

Husk at  $x_i$  ermannens alder ved start og at  $y_i = 1$  hvis mann i har vært hjertesyk i løpet av perioden,  $y_i = 0$  ellers.

```
url = "https://www.uio.no/studier/emner/matnat/math/STK1000/data/wcgs.txt"
wcgs = read.table(url, sep="\t", header=T, na.strings=".")
# R-kommando for logistisk regresjon:
fit=glm(chd69~age, data=wcgs, family=binomial)
summary(fit)
```

**R output (editert):**

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-5.9395	0.5493	-10.813	< 2e-16
age	0.0744	0.0113	6.585	4.56e-11

Odds-ratioen for ett års økning i alder er  $e^{0.0744} = 1.077$

mens ratio for en ti-års-økning er  $e^{0.0744 \times 10} = 2.10$

## 14.2 Konfidensintervall for $\beta_1$ og odds-ratio

95% konfidensintervall for  $\beta_1$  (basert på tilnærming til normalfordelinga):

$$b_1 \pm 1.96 \times SE(b_1)$$

$OR = \exp(\beta_1)$  er odds-ratio for en enhets endring i  $x$

Vi kan lage et 95% konfidensintervall for  $OR$  ved å transformere nedre og øvre grense for konfidensintervallet for  $\beta_1$

R output (editert):

		Estimate	Std. Error	z value	Pr(> z )
I hjerte-eksempelet har vi	(Intercept)	-5.9395	0.5493	-10.813	< 2e-16
	age	0.0744	0.0113	6.585	4.56e-11

$b_1 = 0.0744$  og  $SE(b_1) = 0.0113$  og dermed 95% konfidensinterval for  $\beta_1$ :

$$0.0744 \pm 1.96 \times 0.0113 \quad dvs. \quad fra \ 0.052 \ til \ 0.096$$

Estimat for odds-ratio:  $OR = \exp(0.0744) = 1.077$

95% konfidensintervall for  $OR$ :  $(e^{b_1 - 1.96 \times SE(b_1)}, e^{b_1 + 1.96 \times SE(b_1)})$ , dvs:

fra  $\exp(0.052) = 1.053$  til  $\exp(0.096) = 1.101$

## R-funksjon for å beregne odds-ratio med 95% konfidensgrenser

```
expcoef=function(glmobj)
{
  regtab=summary(glmobj)$coef
  expcoef=exp(regtab[,1])
  lower=expcoef*exp(-1.96*regtab[,2])
  upper=expcoef*exp(1.96*regtab[,2])
  cbind(expcoef,lower,upper)
}
```

```
expcoef(fit)
```

**R output (editert):**

	expcoef	lower	upper
(Intercept)	0.0026	0.0009	0.0077
age	1.077	1.054	1.101

## Wald test for $H_0: \beta_1 = 0$

For å teste nullhypotesen  $H_0: \beta_1 = 0$  mot det tosidige  $H_A: \beta_1 \neq 0$  bruker vi Wald-test-observator:

$$z = \frac{b_1}{SE(b_1)}$$

Vi forkaster  $H_0$  for store verdier av  $|z|$

Under  $H_0$  er testobservatoren *tilnærma standard normalfordelt*.

P-verdi (to-sidig):  $P = 2 P(Z > |z|)$  der  $Z$  er standard normal.

I hjerte-eksemplet har vi  $b_1 = 0.0744$  og  $SE(b_1) = 0.0113$

Wald-test-observator

$$z = 0.0744 / 0.0113 = 6.58$$

som er meget signifikant (den litt mindre p-verdien står angitt i R-utskriften på slide 13)

# Fra enkel til multippel logistisk regresjon

Antar nå at vi for hvert individ har

- en binær respons  $y$
- forklaringsvariable  $x_1, x_2, \dots, x_p$

Vi lar  $p(x_1, x_2, \dots, x_p) = E(y | x_1, x_2, \dots, x_p) = P(y = 1 | x_1, x_2, \dots, x_p)$

Logistisk regresjonsmodell:

$$p(x_1, x_2, \dots, x_p) = \frac{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}{1 + \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}$$

Alternativ definisjon, som i boka:

$$\log\left(\frac{p(x_1, x_2, \dots, x_p)}{1 - p(x_1, x_2, \dots, x_p)}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

En tredje måte å beskrive modellen på er gjennom odds:

$$\frac{p(x_1, x_2, \dots, x_p)}{1 - p(x_1, x_2, \dots, x_p)} = \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)$$

Hvis vi sammenligner to individer med verdiene hhv.  $x_1 + \Delta$  og  $x_1$  for den første forklaringsvariabelen, og parvis identiske verdier for alle de andre forklaringsvariablene, blir odds-ratioen deres

$$\frac{p(x_1 + \Delta, x_2, \dots, x_p) / [1 - p(x_1 + \Delta, x_2, \dots, x_p)]}{p(x_1, x_2, \dots, x_p) / [1 - p(x_1, x_2, \dots, x_p)]} = \frac{\exp(\beta_0 + \beta_1(x_1 + \Delta) + \beta_2 x_2 + \dots + \beta_p x_p)}{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)} = \exp(\beta_1 \Delta)$$

For  $\Delta=1$  ser vi at  $e^{\beta_1}$  er odds-ratioen for en enhets økning i verdien for første kovariat, dersom alle de andre kovariatene holdes fast.

Tilsvarende tolkning holder også for de andre regresjonskoeffisientene.

## La oss se videre på WCGS-studien

med hjertesykdom som respons (som før) og alder, kolesterol (mg/dL), systolisk blodtrykk (mmHg), body mass indeks (kg/m<sup>2</sup>), og røyking (ja, nei) som forklaringsvariable

*Merk at vi har ekskludert et individ med usedvanlig høy verdi av kolesterol-målinga.*

### R-kommando:

```
wcgs.mult=glm(chd69~age+chol+sbp+bmi+smoke, data=wcgs, family=binomial,  
subset=(chol<600))  
summary(wcgs.mult)
```

### R output (editert):

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-12.3110	0.9773	-12.598	< 2e-16
age	0.0644	0.0119	5.412	6.22e-08
chol	0.0107	0.0015	7.079	1.45e-12
sbp	0.0193	0.0041	4.716	2.40e-06
bmi	0.0574	0.0264	2.179	0.0293
smoke	0.6345	0.1401	4.526	6.01e-06

## Odds-ratios med 95% konfidensintervaller

**R-kommando (her kaller vi funksjonen fra slide 15):**

expcoef(wcgs.mult)

**R output (editert):**

	expcoef	lower	upper
(Intercept)	4.50e-06	6.63e-07	3.06e-05
age	1.067	1.042	1.092
chol	1.011	1.008	1.014
sbp	1.019	1.011	1.028
bmi	1.059	1.006	1.115
smoke	1.886	1.433	2.482

Hvert av konfidensintervallene over er funnet ved først å beregne 95% konfidensintervall for  $\beta_j$ , dvs

$$b_j \pm 1.96 \times SE(b_j)$$

og fra dette beregnes 95% konfidensintervall for odds-ratioen for en enhets økning i  $x_j$ , når alle andre kovariater holdes fast:

$$(e^{b_j - 1.96 \times SE(b_j)}, e^{b_j + 1.96 \times SE(b_j)})$$

# Klassifikasjon med logistisk regresjon

- Vi har sett på logistisk regresjon som en regresjonsmodell for kategoriske responsvariable med to kategorier (respons=0 eller 1)
- I situasjoner der man har mer enn to kategorier eksisterer det naturlige utvidelser, men for enkelhets skyld har vi kun sett på binære situasjoner.
- Når vi bruker en estimert/tilpasset logistisk modell til å predikere en kategorisk respons predikerer vi først sannsynligheten for hver av kategoriene, deretter kan vi bruke disse predikerte sannsynlighetene til å velge en predikert kategori. På denne måten kan logistisk regresjon brukes til *klassifikasjon*.
- Logistisk regresjon er en av de mest brukte klassifikatorene, og er en grunnleggende byggestein for mange statistiske/maskinlærings-metoder.