

# Modello logistico (Modello di regressione logistica)

Prof. Giuseppe Verlato

Sezione di Epidemiologia e Statistica Medica,  
Dipartimento di Sanità Pubblica e Medicina di  
Comunità, Università degli Studi di Verona

E per le variabili qualitative NOMINALI ?

2 VARIABILI (entrambe qualitative):  
test del chi-quadrato, test esatto di Fischer

3 VARIABILI qualitative (2 var. + 1 var. di  
stratificazione): test di Mantel-Haenszel

MOLTE VARIABILI:  
y dicotomica (malato/sano) → modello LOGISTICO  
y politomica (fumatore, ex-fumatore, mai-fumatore)  
→ modello MULTINOMIALE

## MODELLO DI REGRESSIONE LOGISTICA

19 / (19+132)	
0 / (0+9)	
11 / (11+52)	
6 / (6+97)	

prevalenze

## MODELLO LOG-LINEARE

19	132
0	9
11	52
6	97

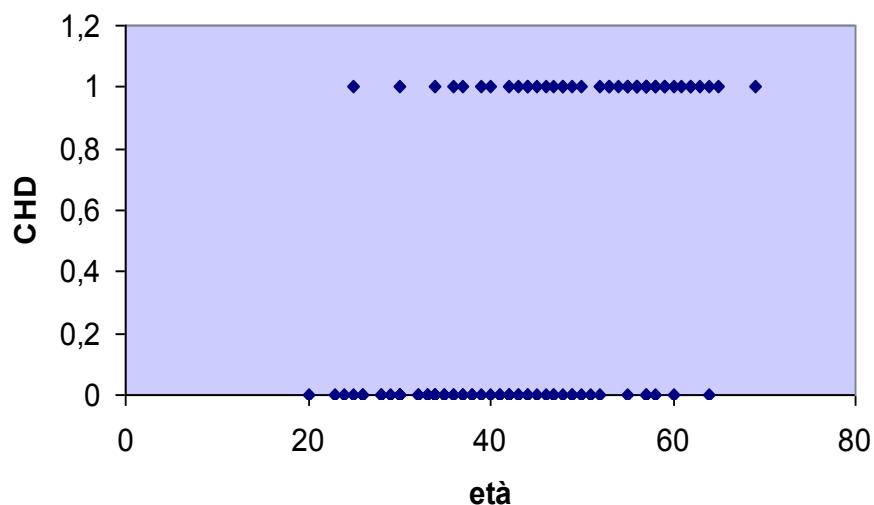
conteggi

## MODELLO DI POISSON

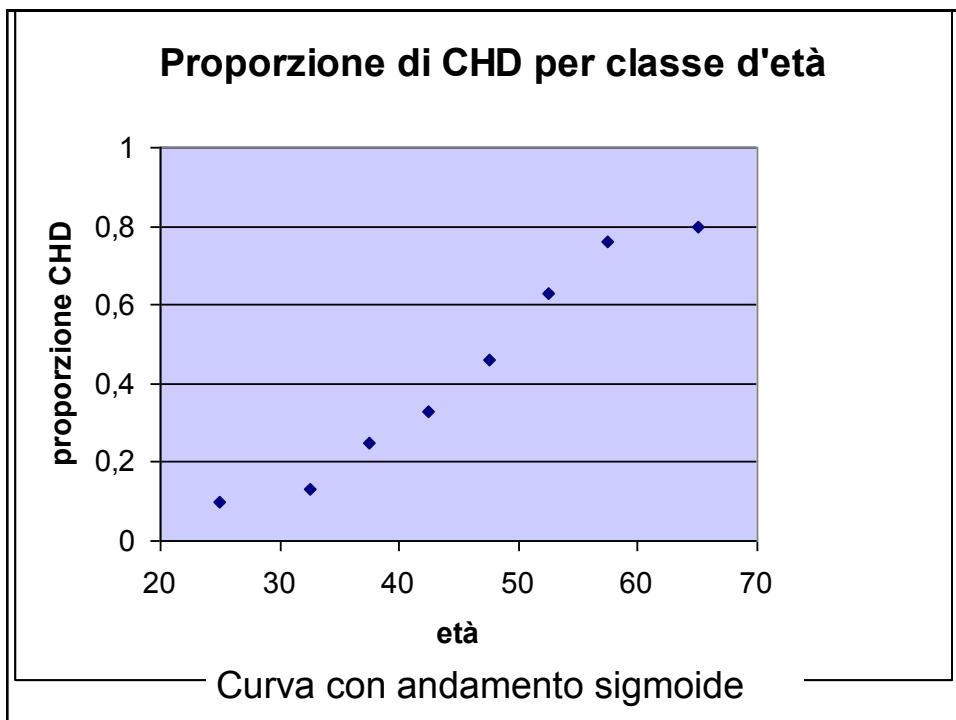
19 / 1510 persone-anno	
0 / 90 persone-anno	
11 / 630 persone-anno	
6 / 103 persone-anno	

incidenze

## Presenza di CHD in base all'età



CHD				
classe d'età	N	assente	presente	proporzione
20-29	10	9	1	0,1
30-34	15	13	2	0,13
35-39	12	9	3	0,25
40-44	15	10	5	0,33
45-49	13	7	6	0,46
50-54	8	3	5	0,63
55-59	17	4	13	0,76
60-69	10	2	8	0,8
<b>totale</b>	<b>100</b>	<b>57</b>	<b>43</b>	<b>0,43</b>



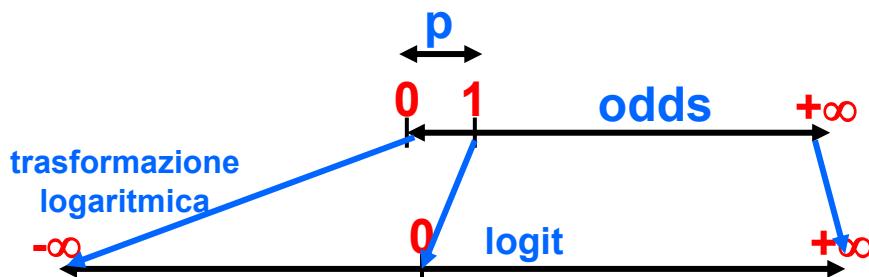
Nella regressione lineare multipla la Y varia tra  $-\infty$  e  $+\infty$

**Nella regressione logistica**

$p(\text{malattia})$  varia tra 0 e 1

$\text{odds}(\text{malattia}) = p/(1-p)$  varia tra 0 e  $+\infty$

**Logit** =  $\ln[p/(1-p)]$  varia tra  $-\infty$  e  $+\infty$



I MODELLI LINEARI GENERALIZZATI si differenziano per la **distribuzione dell'errore (error function)** e per la **funzione legame (link function)**

#### REGRESSIONE LINEARE MULTIPLA

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{13} x_1 x_3 + \varepsilon$$

La funzione legame (link-function) è l'**IDENTITÀ**  
L'errore segue la **DISTRIBUZIONE NORMALE**

#### MODELLO DI REGRESSIONE LOGISTICA

$$\ln[y/(1-y)] = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{13} x_1 x_3 + \varepsilon$$

La funzione legame (link-function) è il **LOGIT [LOG(ODDS)]**  
L'errore segue la **DISTRIBUZIONE BERNOULLIANA**

#### MODELLO LOG-LINEARE

$$\ln(y) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{13} x_1 x_3 + \varepsilon$$

La funzione legame (link-function) è il **LOGARITMO**  
L'errore segue la **DISTRIBUZIONE DI POISSON**

## MODELLO DI REGRESSIONE LOGISTICA

**Predittore lineare**

$$\ln [\pi/(1-\pi)] = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{13} x_1 x_3$$

**Logit**

Var.qualitative  
e/o quantitative

Termine  
d'interazione

$$\pi/(1-\pi) = \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{13} x_1 x_3)$$

odds

$$\pi = \frac{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{13} x_1 x_3)}{1 + \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{13} x_1 x_3)}$$

## Metodi di ottimizzazione

per trovare il modello che meglio si adatta ai dati

Se la funzione-legame è l'identità:  
 Regressione lineare semplice  
 Regressione lineare multipla  
 Analisi della varianza  
 Analisi della covarianza

Omoschedasticità  
 $\varepsilon \sim N(0; \sigma^2)$

Metodo dei minimi quadrati  
 (least-square method)

Regressione logistica

Non-Omoschedasticità  
 $\varepsilon \sim B(0; \pi(1-\pi))$

Metodo della massima  
 verosimiglianza  
 (maximum likelihood)  
 Metodo iterativo

## 30 FIGLI MASCHI SU 40 NASCITE

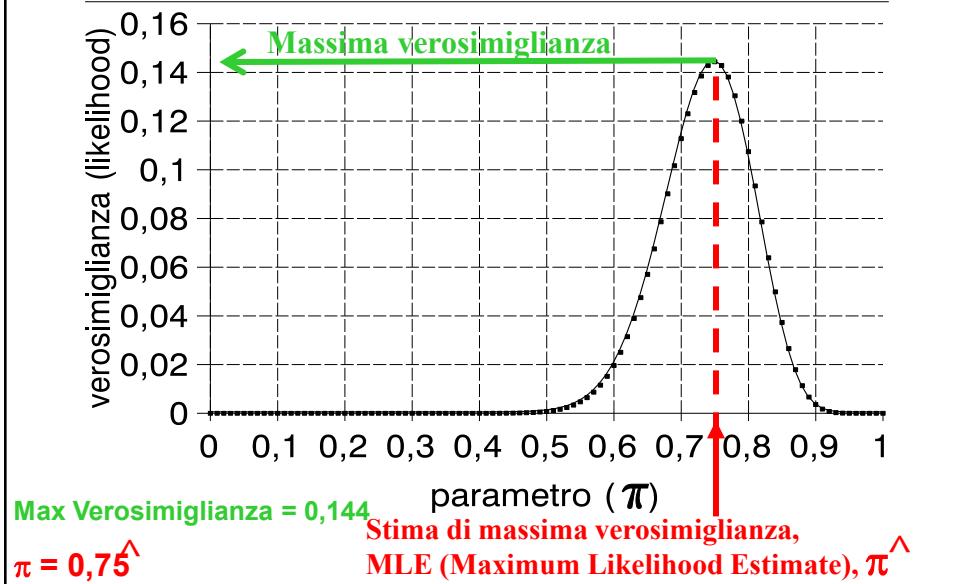


Table 4. Risk factors for e-cigarette ever use.

Risk factors	OR of e-cigarette ever use (95%IC)	p-value
<b>Smoking Habits</b>		
Never Smokers	1	
Ex-Smokers	<b>5.97 (3.46 – 10.33)</b>	<0.001
Occasional Smokers	<b>7.75 (5.07 – 11.85)</b>	<0.001
Regular Smoker	<b>24.6 (16.62 – 36.50)</b>	<0.001
<b>Sex</b>		
Male	1	
Female	<b>0.45 (0.32 – 0.63)</b>	<0.001
<b>Family history of smoking</b>		
None	1	
Relative who smoked e-cig	0.68 (0.37 – 1.25)	0.219
Relative who smoked tobacco	1.19 (0.92 – 1.53)	0.178
<b>Housemates currently smoking</b>		
None	1	
Housemates smoking e-cig	<b>2.54 (1.15 – 5.59)</b>	<b>0.021</b>
Housemates smoking tobacco	1.16 (0.94 – 1.43)	0.163
<b>Centre</b>		
Verona	1	
Vicenza	<b>1.12 (1.01 – 1.24)</b>	<b>0.027</b>
Legnago	<b>0.89 (0.85 – 0.94)</b>	<0.001
Trento	<b>0.82 (0.73 – 0.91)</b>	<0.001
Bolzano	<b>0.66 (0.63 – 0.69)</b>	<0.001
<b>University class</b>		
1 <sup>st</sup> year	1	
2 <sup>nd</sup> year	1.01 (0.73 – 1.41)	0.939
3 <sup>rd</sup> year	0.79 (0.56 – 1.11)	0.173

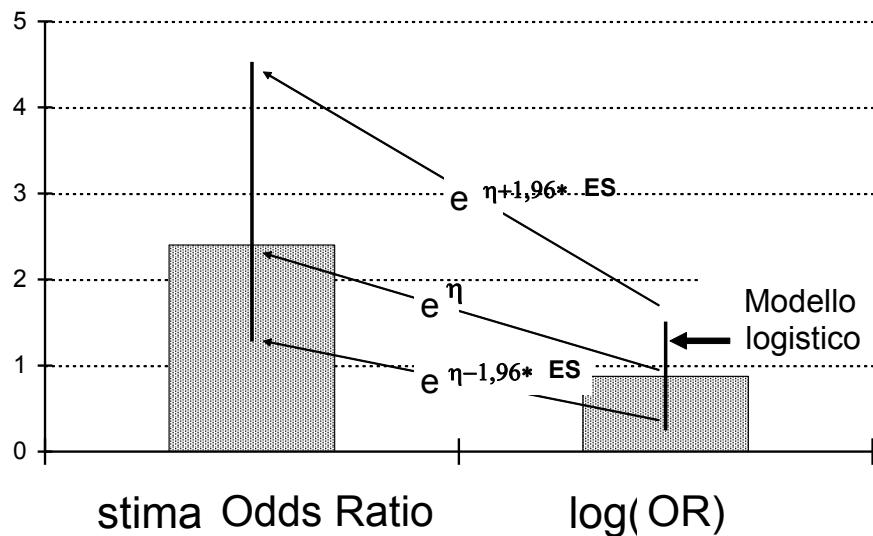
Canzan et al, BMC  
 Public Health 2019

OR (Odds Ratio), 95% IC, P-values were computed by logistic regression model.  
 Significant results were highlighted in bold.

Logistic regression						
					Number of obs	= 1,354
					LR chi2(14)	= 476.34
					Prob > chi2	= 0.0000
					Pseudo R2	= 0.2852
Log likelihood =	-597.07448					
provatoecg	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_IsmokHab_1	1.787651	.2388358	7.48	0.000	1.319541	2.25576
_IsmokHab_2	2.047776	.2235388	9.16	0.000	1.609648	2.485904
_IsmokHab_3	3.203935	.1918879	16.70	0.000	2.827841	3.580028
_Isesso_2	-.8049849	.1684709	-4.78	0.000	-1.135182	-.4747881
Ifamiliari_1	-.3819719	.2876365	-1.33	0.184	-.9457291	.1817854
Ifamiliari_2	.1720737	.1825327	0.94	0.346	-.1856837	.5298312
Iconvivent_1	.9307554	.3162551	2.94	0.003	.3109068	1.550604
Iconvivent_2	.1494138	.1920308	0.78	0.437	-.2269596	.5257873
_Isede_2	.1159116	.2095446	0.55	0.580	-.2947882	.5266115
_Isede_3	-.1109284	.2274942	-0.49	0.626	-.5568088	.334952
_Isede_4	-.2020076	.2462749	-0.82	0.412	-.6846976	.2806824
_Isede_5	-.4146958	.2101358	-1.97	0.048	-.8265544	-.0028371
Iannodicor_2	.0129026	.1907115	0.07	0.946	-.360885	.3866903
Iannodicor_3	-.2393992	.1827322	-1.31	0.190	-.5975477	.1187494
_cons	-1.872191	.2466523	-7.59	0.000	-2.355621	-1.388762

## CONSEGUENZE della TRASFORMAZIONE LOGARITMICA:

L'intervallo di confidenza diventa asimmetrico



Quando abbiamo una sola variabile indipendente, possiamo verificare che il parametro  $\beta$  stimato dalla regressione logistica corrisponde al  $\ln(\text{OR})$  calcolato dalla tabellina corrispondente.

Es. Età e CHD: dividiamo l'età in 2 categorie  $<55(x=0)$  e  $\geq 55(x=1)$

	Coefficiente Stimato	Errore Standard	Coeff./ES	OR
AGE	2.094	0.529	3.96	8.1
Constant	-0.841	0.255	-3.30	

Costruendo ora la tabellina 2X2:

	AGE(x)		
CHD (y)	$\geq 55(1)$	$<55$	
Presente (1)	21	22	43
Assente (0)	6	51	57
Totale	27	73	100

$$\text{OR} = 21 * 51 / (6 * 22) = 8.11$$

che quindi corrisponde a quanto trovato con la regressione logistica