

## Corso Integrato di Statistica Informatica e Analisi dei dati

Dr Carlo Meneghini

Dip. di Fisica "E. Amaldi"  
via della Vasca Navale 84

meneghini@fis.uniroma3.it

http://webusers.fis.uniroma3.it/~meneghini

### Confronto dati sperimentali e distribuzioni teoriche di probabilità

C.I. - statistica, informatica e analisi dei dati sperimentali


1

## Principali distribuzioni di probabilità discrete

### Binomiale

$$P(k) = \frac{N!}{k!(N-k)!} p^k (1-p)^{N-k}$$

$$\begin{aligned} \mu_{bin} &= Np \\ \sigma_{bin}^2 &= Np(1-p) \\ \sigma_{bin} &= \sqrt{Np(1-p)} \end{aligned}$$



C.I. - statistica, informatica e analisi dei dati sperimentali


2

## Principali distribuzioni di probabilità discrete

### Poisson

$$P(x) = \frac{\lambda^x}{x!} e^{-\lambda}$$

$$\begin{aligned} \mu_{pois} &= \lambda \\ \sigma_{pois}^2 &= \lambda \\ \sigma_{pois} &= \sqrt{\lambda} \end{aligned}$$



C.I. - statistica, informatica e analisi dei dati sperimentali

3

## Distribuzioni di probabilità continue

$F(x)$  = funzione di distribuzione di probabilità

$$F(x) = \int_{-\infty}^x p(x) dx$$

Probabilità di osservare un valore della variabile  $X$  tra  $x_a$  e  $x_b$

$$P(x_a \leq X \leq x_b) = F(x_b) - F(x_a)$$

$p(x)$  = funzione di densità di probabilità

$$p(x) = \frac{dF(x)}{dx} = F'(x)$$

$p(x)dx$  = probabilità di osservare un valore della variabile  $X$  compreso tra  $x$  e  $x+dx$

$$dx p(x) = P(x \leq X \leq x + dx)$$

C.I. - statistica, informatica e analisi dei dati sperimentali

4


## Principali distribuzioni di probabilità continue

### Uniforme

$$p_{uni}(x) = \begin{cases} \frac{1}{x_b - x_a} & x_a \leq x \leq x_b \\ 0 & (x < x_a), (x > x_b) \end{cases}$$

$$\begin{aligned} \mu_{uni} &= \frac{x_a + x_b}{2} \\ \sigma_{uni}^2 &= \frac{(x_b - x_a)^2}{12} \\ \sigma_{uni} &= \frac{x_b - x_a}{\sqrt{12}} \end{aligned}$$

$$P_{uni}(x_1 \leq X \leq x_2) = \int_{x_1}^{x_2} p(x) dx = \frac{x_2 - x_1}{x_b - x_a}$$



C.I. - statistica, informatica e analisi dei dati sperimentali

5

## Principali distribuzioni di probabilità continue

### Gauss (Normale)

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$



$\mu$	7.4
$\sigma$	2.3

$$P(\mu - \sigma \leq X \leq \mu + \sigma) = 0.682$$

$$P(\mu - 1.96\sigma \leq X \leq \mu + 1.96\sigma) = 0.95$$

$$P(\mu - 2\sigma \leq X \leq \mu + 2\sigma) = 0.954$$

$$P(\mu - 3\sigma \leq X \leq \mu + 3\sigma) = 0.997$$




dei dati sperimentali

## Principali distribuzioni di probabilità continue

### Gauss (Normale)

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$




$$P(\mu - \sigma \leq X \leq \mu + \sigma) = 0.682$$


$$P(\mu - 1.96\sigma \leq X \leq \mu + 1.96\sigma) = 0.95$$

$$P(\mu - 2\sigma \leq X \leq \mu + 2\sigma) = 0.954$$


$$P(\mu - 3\sigma \leq X \leq \mu + 3\sigma) = 0.997$$



dei dati sperimentali




**Istogramma:**  
L'area del rettangolo rappresenta la frequenza di una classe, l'altezza la densità di frequenza.  
Il centro della base rappresenta il valore di riferimento.



formatica e analisi dei dati sperimentali

## incertezza di misura

La funzione di distribuzione binomiale è la funzione di distribuzione da cui provengono le frequenze di un istogramma costruito a partire dalle misure sperimentali.



In questo caso  
Il numero totale di prove:  $N_T = 30$   
Consideriamo *successo* il fatto di osservare un valore nella classe 5 e *insuccesso* qualunque altro valore  
Il numero di volte che abbiamo osservato il valore 5 è 3 quindi, in base ai dati sperimentali la probabilità di successo è:  
 $p_5 = 3/N_T = 0.1$

C.I. - statistica, informatica e analisi dei dati sperimentali


## incertezza di misura

La funzione di distribuzione binomiale è la funzione di distribuzione da cui provengono le frequenze di un istogramma costruito a partire dalle misure sperimentali.

In base ai dati sperimentali il numero di volte che è lecito aspettarsi di trovare 5 fagioli neri pescando  $N_T$  fagioli è (valore atteso)  
 $\mu = N_T p_5$   
L'incertezza è:  
 $\sigma^2 = N_T p_5(1-p_5)$

È lecito aspettarsi che, ripetendo l'esperimento, le osservazioni sperimentali siano distribuite intorno al valore vero e che queste siano più frequenti nell'intervallo  $\mu - \sigma, \mu + \sigma$

La deviazione standard  $\sigma$  è l'incertezza standard sul valore osservato.



C.I. - statistica, informatica e analisi dei dati sperimentali

## L'incertezza standard sul numero di sul valore osservato in una data classe è $\sigma_i$

**Dati sperimentali**

Pescata	n. fagioli neri
1	9
2	3
3	5
4	2
5	6
6	10
7	10
8	3
9	8
10	8
11	7
12	5
13	6
14	6
15	6
16	6
17	8
18	7
19	7
20	6
21	7
22	4
23	6
24	6
25	6
26	6
27	3
28	6
29	10
30	7

**Riepilogo Statistiche**

media:	6.4
dev. st:	2.1
max:	10
min:	2
N. oss:	30

**Istogramma di frequenza**

classi	Freq. ass.	err. F	freq. rel.	err. Freq. rel.
0	0	0.000	0.000	0.000
1	0	0.000	0.000	0.000
2	1	1.0	0.033	0.033
3	3	1.7	0.100	0.058
4	1	1.0	0.033	0.033
5	3	1.7	0.100	0.058
6	9	3.0	0.300	0.100
7	5	2.2	0.167	0.075
8	3	1.7	0.100	0.058
9	2	1.4	0.067	0.047
10	3	1.7	0.100	0.058
11	0	0.000	0.000	0.000

$N_i$

$f_i = \frac{N_i}{N_T} \sim p_i$

$\sigma_i = \sqrt{f_i N_T (1 - f_i)}$

$\sigma_i \sim \sqrt{f_i N_T} \sim \sqrt{N_i}$

$\sigma_{f_i} = \frac{\sigma_i}{N_i} \sim \frac{1}{\sqrt{N_i}}$

C.I. - statistica, informatica e analisi dei dati sperimentali

## incertezza di misura

### L'incertezza standard sul numero di sul valore osservato in una data classe è $\sigma_i$

**Istogramma Dati sperimentali**

classi	Freq. ass.	freq. rel.	err. Freq. rel.
0	0	0.000	0.000
1	0	0.000	0.000
2	1	0.033	0.033
3	3	0.100	0.058
4	1	0.033	0.033
5	3	0.100	0.058
6	9	0.300	0.100
7	5	0.167	0.075
8	3	0.100	0.058
9	2	0.067	0.047
10	3	0.100	0.058
11	0	0.000	0.000

**Right-click**

Formato serie dati...

Dati di origine...

Aggiungi linea di tendenza...

Cancella

C.I. - statistica, informatica e analisi dei dati sperimentali

## Confronto dati sperimentali e distribuzioni teoriche

### Distribuzioni discrete

Problema:

Confrontare la distribuzione sperimentale (N dati con distribuzione di frequenze assolute  $N_i$ ) con la distribuzione teorica di probabilità  $P(x)$ . Una volta costruito l'istogramma di frequenze sperimentali:

**A**

Calcolare la distribuzione delle frequenze relative  $f_{exp}$

Calcolare l'incertezza sulle frequenze assolute:  $\sigma_i = \sqrt{f_i N_T (1 - f_i)}$

$$\sigma_i \sim \sqrt{f_i N_T} \sim \sqrt{N_i}$$

Calcolare l'incertezza sulle frequenze relative  $\sigma_{f_i} = \frac{\sigma_i}{N_i} \sim \frac{1}{\sqrt{N_i}}$

Riportare sul grafico  $P(x)$  e  $f_{exp}$  con le incertezze di misura

**B**

Calcolare l'incertezza sulle frequenze assolute:  $\sigma_i = \sqrt{f_i N_T (1 - f_i)}$


$$\sigma_i \sim \sqrt{f_i N_T} \sim \sqrt{N_i}$$

Calcolare le frequenze assolute teoriche:

$$N_{Th} = p_i N_T$$

Riportare sul grafico  $N_{Th}$  e  $N_i$  con le incertezze di misura

## Confronto dati sperimentali e distribuzioni teoriche



Istogramma Dati sperimentali					Istogramma teorico					Parametri Binomiali	
classi	Freq. ass.	err. F	freq. rel.	err. Freq. rel.	freq. ass.	freq. rel.	freq. ass.	freq. rel.	N	p	
0	0	0.0	0.000	0.000	0.007	0.000	0.000	0.000	12	0.5	
1	0	0.0	0.000	0.000	0.088	0.003	0.000	0.000			
2	1	1.0	0.033	0.033	0.483	0.016	0.000	0.000			
3	3	1.6	0.100	0.055	1.511	0.054	0.000	0.000			
4	1	1.0	0.033	0.033	3.625	0.121	0.000	0.000			
5	3	1.6	0.100	0.055	5.801	0.193	0.000	0.000			
6	9	2.5	0.300	0.084	6.769	0.226	0.000	0.000			
7	5	2.0	0.167	0.068	5.801	0.193	0.000	0.000			
8	3	1.6	0.100	0.055	3.625	0.121	0.000	0.000			
9	2	1.4	0.067	0.040	1.511	0.054	0.000	0.000			
10	3	1.6	0.100	0.055	0.483	0.016	0.000	0.000			
11	0	0.0	0.000	0.000	0.088	0.003	0.000	0.000			

## Confronto dati sperimentali e distribuzioni teoriche: classi con più di un carattere (valore)

**Dati sperimentali**

Pescata	n. fagioli neri
1	9
2	3
3	5
4	2
5	6
6	10
7	10
8	3
9	8
10	7
11	6
12	5
13	6
14	6
15	6
16	6
17	7
18	7
19	7
20	7
21	7
22	4
23	3
24	6
25	6
26	6
27	3
28	6
29	10
30	7

**Riepilogo Statistiche**

media	6.4
dev. st.	2.1
max	10
min	2
N. oss.	30

Istogramma Dati sperimentali					Istogramma teorico					Parametri Binomiali	
classi	Freq. ass.	err. F	freq. rel.	err. Freq. rel.	freq. ass.	freq. rel.	freq. ass.	freq. rel.	N	p	
4	0	0.0	0.000	0.000	0.007	0.000	0.000	0.000	12	0.5	
5	2	1.0	0.033	0.033	0.571	0.019	0.000	0.000			
6	4	2.0	0.133	0.062	5.239	0.175	0.000	0.000			
7	6	2.5	0.200	0.089	12.559	0.419	0.000	0.000			
8	8	2.8	0.267	0.081	9.426	0.314	0.000	0.000			
9	10	3.2	0.333	0.068	7.166	0.239	0.000	0.000			
10	12	3.5	0.400	0.060	0.956	0.032	0.000	0.000			

Per una classe i-esima la funzione FREQUENZA di Excel calcola  $F(i) - F(i-1) = N_i - N_{i-1}$

Questo valore deve essere confrontato con la Pb di osservare il valore i-esimo oppure i-1 esimo

Vedere l'esempio nel file: [confronto2.xls](#)

## Confronto dati sperimentali e distribuzioni teoriche: distribuzioni continue

**Dati sperimentali**

Complesso	Pesca(g)
4	41.11
5	51.02
6	51.93
7	51.94
8	50.94
9	57.12
10	54.66
11	57.09
12	59.89
13	53.02
14	53.12
15	59.38
16	59.38

**Riepilogo Statistiche**

media	53.5
dev. st.	4.5
max	60.27
min	41.11
N. oss.	30

Istogramma Dati sperimentali					Istogramma teorico					Parametri Gauss.	
classi	Freq. ass.	err. F	freq. rel.	err. Freq. rel.	freq. ass.	freq. rel.	freq. ass.	freq. rel.	μ	σ	
40	42	4.1	0.0	0.000	0.000	0.001	0.000	0.000	54	3	
41	44	4.3	1.0	0.033	0.033	0.012	0.000	0.000			
42	46	4.5	0.0	0.000	0.000	0.102	0.003	0.000			
43	48	4.7	1.0	0.033	0.033	0.269	0.019	0.000			
44	49	4.9	3	0.100	0.055	2.054	0.068	0.000			
45	50	5.1	2	0.067	0.033	4.888	0.161	0.000			
46	51	5.2	4	0.133	0.052	7.425	0.248	0.000			
47	52	5.3	6	0.200	0.071	7.425	0.248	0.000			
48	53	5.4	4	0.133	0.052	4.888	0.161	0.000			
49	54	5.5	8	0.267	0.089	2.054	0.068	0.000			
50	55	5.6	2	0.067	0.033	0.269	0.019	0.000			
51	56	5.7	1	0.033	0.016	0.102	0.003	0.000			
52	57	5.8	3	0.100	0.055	0.269	0.019	0.000			
53	58	5.9	5	0.167	0.068	0.269	0.019	0.000			
54	59	6.0	3	0.100	0.055	0.269	0.019	0.000			
55	60	6.1	0	0.000	0.000	0.102	0.003	0.000			

Per una distribuzione continua la probabilità associata ad un intervallo di valori (classe) si calcola a partire dalla distribuzione integrata:

$$P(x_1 < X < x_2) = F(x_2) - F(x_1)$$

Vedere l'esempio nel file: [confronto3.xls](#)