

# Esperimenti al calcolatore

Andrea Marin

Università Ca' Foscari di Venezia  
Dipartimento di Informatica  
Corso di Probabilità e Statistica

2009

# Indice

- 1 **Questione di definizioni**
  - Definizione classica
  - Definizione frequentista
  - Definizione soggettiva
  - Definizione assiomatica
  - Paradosso delle 3 carte (W. Weaver 1950)
- 2 **Generare numeri (pseudo) casuali**
  - Introduzione
  - Generatori lineari congruenziali
  - Marsenne twister
- 3 **Tornando a Octave**
  - Uso delle funzioni per la generazione
- 4 **Prima esercitazione**

## Diverse definizioni di probabilità

Storicamente si sono affermate diverse definizioni di probabilità. Le principali sono:

- Definizione classica
- Definizione frequentista
- Definizione soggettiva
- Definizione assiomatica

## Definizione classica

- Probabilmente dovuta a Laplace (1800 ca.)
- La probabilità di un evento è definita come il rapporto tra il numero di casi favorevoli all'evento e il numero di casi possibili, purchè questi ultimi siano tutti equiprobabili
- Quali problemi con questa definizione?

## Problemi della definizione classica

- È una definizione **circolare**. Necessita del concetto di equiprobabile per dare la definizione di probabilità
- È applicabile solo in caso di eventi equiprobabili
- Il numero di risultati possibili deve essere finito  $\Rightarrow$  non utilizzabile al continuo

## Definizione frequentista

- Introdotta da von Mises (1883-1953)
- La probabilità di un evento è definita come il limite cui tende la frequenza relativa dell'evento al crescere del numero degli esperimenti
- Se  $n_A$  è il numero di osservazioni dell'evento  $a$  su  $n$  esperimenti, allora la probabilità  $P(A)$  è:

$$P(A) = \lim_{n \rightarrow +\infty} \frac{n_A}{n}$$

- Negli esperimenti di laboratorio faremo riferimento a questa definizione (in opposizione a quella assiomatica vista nel corso di teoria)

## Limiti della definizione frequentista

- Richiede la ripetibilità degli eventi: intuitivamente invece è possibile assegnare una probabilità anche agli eventi non ripetibili
- La definizione del limite  $p_a$  in questo caso non è compatibile con quella dell'analisi.

$$\forall \epsilon > 0, \quad \exists N : \forall n > N, \quad |n_a/n - p_a| < \epsilon$$

- È possibile determinare  $N$ ?

## Definizione soggettiva

- Introdotta da de Finetti (1906-1985) e Savage (1917-1971)
- La probabilità di un evento è definita come il prezzo che un individuo ritiene equo pagare per ricevere 1 se l'evento si verifica e 0 altrimenti
- Le probabilità devono essere assegnate in modo da evitare la vincita o la perdita certa (criterio di coerenza)
- Problemi: la soggettività (e.g. Superenalotto)



## Definizione assiomatica

- Introdotta da Kolmogorov nel 1933
- Non si tratta di una definizione operativa (la probabilità è vista come misura)
- Il calcolo è basato su un insieme di assiomi
- (Dettagli visti a lezione)

## Il paradosso delle 3 carte

- Si hanno a disposizione 3 carte. Una ha entrambe le facce rosse, una ha una faccia rossa e una bianca, l'ultima due bianche. Si dispongono le carte voltate a caso e si pesca una carta osservando che il dorso è rosso. Qual è la probabilità che la faccia sia anch'essa rossa?
- Intuizione?
- Approccio classico?
- Approccio frequentista?
- Approccio assiomatico?

## Approccio classico

- Identifichiamo ciascuna faccia delle carte con un numero:
  - RR  $\rightarrow$  12
  - RB  $\rightarrow$  34
  - BB  $\rightarrow$  56
- Vediamo tutte le possibili scelte:

Scelta	Altra faccia	Possibile?	Favorevole?
1	2	SI	SI
2	1	SI	SI
3	4	SI	NO
4	3	NO	NO
5	6	NO	NO
6	5	NO	NO

- Numero dei favorevoli su numero dei possibili =  $2/3$

## Approccio assiomatico

- Si vuole calcolare
$$P\{\text{faccia nascosta rossa} \mid \text{faccia visibile rossa}\} = P\{F_n = R \mid F_v = R\}$$
- Notiamo che  $P\{F_n = R \mid F_v = R\} = P\{\text{Carta tutta rossa} \mid F_v = R\} = P\{C = RR \mid F_v = R\}$
- Per il teorema di Bayes abbiamo:

$$P\{C = RR \mid F_v = R\} = \frac{P\{F_v = R \mid C = RR\}P\{C = RR\}}{P\{F_v = R\}}$$

- Attribuiamo la misura di probabilità agli eventi
  - Nota che questo viene fatto di solito usando un approccio classico/frequentista
  - $P\{F_v = R\} = 1/2$  (3 facce su 6 sono rosse)
  - $P\{C = RR\} = 1/3$
  - $P\{F_v = R \mid C = RR\} = 1$

## La funzione rand

- `rand`: restituisce un numero pseudo-casuale nell'intervallo  $(0, 1)$ , distribuzione uniforme
- `rand(d)`: restituisce una matrice  $d \times d$  di numeri pseudo-casuali nell'intervallo  $(0, 1)$ , d.u.
- `rand(d1, d2)`: restituisce una matrice  $d1 \times d2$  di numeri pseudo-casuali

Ma prima...

### Citazione

La generazione dei numeri casuali è troppo importante per essere lasciata al caso. [R.R. Coveyou]

# Utilità dei generatori di numeri pseudo-casuali

I generatori di numeri casuali (RNGs) sono utilizzati in molti contesti:

- Esperimenti statistici
- Simulazione di sistemi stocastici
- Analisi numerica basata su metodi Monte-Carlo
- Algoritmi probabilistici
- Computer games
- Crittografia
- Protocolli di comunicazione sicuri

# Caratteristiche di un generatore pseudo-casuali

Un generatore di numeri pseudo-casuali **simula** il comportamento di una sequenza di v.c. indipendenti

- il programma che implementa il generatore è deterministico
- a parità di seme iniziale la sequenza di output è la stessa

Caratteristiche:

- Ciascun numero dell'intervallo dovrebbe avere la stessa probabilità di estrazione
- Le estrazioni non dovrebbero essere correlate

## Definizione di RNG

### Definition (RNG)

Un RNG può essere definito come una struttra  $(S; \mu; f; U; g)$  dove:

- $S$  insieme finito di stati
- $\mu$  è una distribuzione di probabilità su  $S$  usata per la selezione dello stato iniziale  $S_0$  (seme)
- $f : S \rightarrow S$  è una funzione di transizione
- $U$ : è un insieme finito di simboli
- $g : S \rightarrow U$  è la funzione di output

Se  $s_n$  è lo stato all' $n$ -ma estrazione, lo stato successivo è:  
 $s_{n+1} = f(s_n)$ . L'uscita corrispondente è  $g(s_{n+1}) \in U$ .



## Periodo del generatore

### Definition (Periodo del generatore)

Il periodo di un generatore RNG è il più piccolo  $\ell > 0$  tale che  $s_i = s_{\ell+i}$  per ogni  $s_i \in S$ .

- Proprietà: si può dimostrare che  $\ell \leq |S|$ .
- Valori grandi di  $\ell$  sono auspicabili

## Esempio

Realizzazione di un RNG nell'intervallo  $[0, 1]$

- $S = \{0, \dots, 2^{20}\}$
- $U = [0, 1]$  (attenzione!)
- 

$$f(s_i) = s_{i+1} = \begin{cases} s_i + 1 & \text{se } s_i < 2^{20} \\ 0 & \text{se } s_i = 2^{20} \end{cases}$$

- $g(s_i) = u_i = s_i/2^{20}$
- $s_0 = 0$

Attenzione: pessimo generatore! (anche se si pu' aumentare la periodicit  a piacere)

## Proprietà di un buon generatore

- *Lunghezza del periodo*: periodi lunghi assicurano che non vi siano cicli prevedibili
- *Efficienza*: uso di poche risorse tempo/memoria
- *Ripetibilità*: partendo dallo stesso seme riproducono la stessa sequenza
- *Portabilità*: devono essere indipendenti dalla piattaforma

# Generatori lineari congruenziali

- Sono generatori molto efficienti e diffusi
- Sono caratterizzati da una funzione  $f$  dalla forma:

$$s_{i+1} = f(s_i) = [a \cdot s_i + c](\text{mod } m)$$

- $a$  viene chiamato moltiplicatore
- $c$  incremento

## Esempio didattico

Consideriamo il generatore congruenziale con  $a = 1$ ,  $c = 6$ ,  $m = 5$ ,  
 $s_0 = 1$ .

La sequenza generata è la seguente:

$s_0 = 1$ ,  $s_1 = 4$ ,  $s_2 = 3$ ,  $s_3 = 0$ ,  $s_4 = 1$ , ...

- Periodo  $\ell = 4$
- Alcuni numeri non vengono estratti...

# Implementazioni di RNG congruenziale

Implementazione	$m$	$a$	$c$	$g$
Borland C/C++	$2^{32}$	22695477	1	bits 30...16
glibc (usato da GCC)	$2^{32}$	1103515245	12345	bits 30...0
ANSI C: Watcom, Digital Mars, CodeWarrior, IBM VisualAge C/C++	$2^{32}$	1103515245	12345	bits 30...16
Borland Delphi, Virtual Pascal	$2^{32}$	134775813	1	bits 63...32 of (seed * L)
Microsoft Visual/Quick C/C++	$2^{32}$	214013	2531011	bits 30...16
Random class nelle API di Java	$2^{48}$	25214903917	11	bits 48...17

## Problemi dei generatori congruenziali

- Periodo lungo al massimo  $m$
- Il periodo  $\ell$  è determinato dai parametri  $a$ ,  $c$ ,  $m$ ,  $s_0$
- C'è una marcata correlazione tra chiamate successive al generatore

Cos'è la correlazione?

- Prendiamo uno spazio  $k$  dimensionale
- Siano  $(n_1, \dots, n_k)$  le coordinate di un punto dello spazio
- Se le coordinate del punto sono estrazioni successive del generatore allora i punti si dispongono su iperpiani
- Il numero di iperpiani massimo è dato da  $m^{\frac{1}{k}}$ .
- Vedi applicazione Java...

# RNG Marsenne Twister

- RNG molto veloce (paragonabile alla `rand` dell'ANSI C)
- Richiede relativamente poche risorse
- Sviluppato nel 1997 da Matsumoto e Nishimura
- 'E il generatore di default di Octave
- Bassa correlazione
- periodo di  $2^{19937}$

ma attenzione... Dal manuale di Octave:

“Do not use for cryptography without securely hashing several returned values together, otherwise the generator state can be learned after reading 624 consecutive values.”



## Modifica del seed

- `v = rand('state')`: legge il seed corrente e lo mette nella variabile `v`.
- `rand('state', val)`: imposta il seed
- Per default il seed è impostato col valore estratto da `/dev/urandom`. Se non è disponibile si usa il clock di sistema.
- `rand('seed', val)`: imposta il seed del generatore a congruenza. Se l'ultima impostazione è stata fatta con `seed` verrà utilizzato il generatore congruenziale, se è stata fatta con `state` il Marsenne Twister

Attenzione: nelle relazioni, per una questione di replicabilità degli esperimenti allegare un file con il seed utilizzato.

## Esempi

- `n = floor(rand * 100)`: estrae un numero casuale tra 0 e 99
- `d = floor(rand * 6) + 1`: estrae un numero casuale tra 1 e 6
- `n = floor(rand(100,1)*50)+ones(100,1)`: estrae un vettore colonna di numeri casuali tra 0 e 49

## Quante prove?

- Selezioniamo  $N$  numeri casuali in  $(0, 1)$  con distribuzione uniforme
- Quanto ci aspettiamo sia la media dei numeri selezionati?
  - 0.5

$N$	media	errore
10	0.44142	0.05858
50	0.47188	0.028125
100	0.49910	$9.0E - 4$
500	0.50276	0.0027559
1000	0.50870	0.0086974

- Test con Octave...

- Come fare quando non si conosce il valore atteso?

## Primo esercizio

Si dispone di un dado a sei facce. Un esperimento consiste in questo: lanciato il dado, lo si rilancia soltanto se il valore uscito è minore o uguale a 3. In questo caso, il valore ottenuto è accettabile se la somma dei due lanci è minore o uguale di 6.

Riassumendo, l'esito dell'esperimento può essere:

- accettabile con un lancio ( $R \geq 4$ ),
- accettabile con due lanci ( $2 \leq R \leq 6$ ),
- non accettabile.

Si desidera conoscere:

- 1 Il valore medio dei punteggi totalizzati dagli esperimenti considerati accettabili
- 2 La probabilità che un esperimento sia accettabile

a- Scrivere un'applicazione che stimi il valore medio e la probabilità per simulazione b- Confrontare i risultati sperimentali con quelli teorici

## Da consegnare entro il 22/03/2010

- Documento PDF che illustri i risultati della simulazione e analisi teoriche
  - Introduzione
  - Formalizzazione del problema
  - Analisi teorica
  - Descrizione del simulatore
  - Descrizione dell'esperimento
  - Esisti dell'esperimento
  - Conclusione e discussione dei risultati
- Sorgenti e altri file necessari per ripetere gli esperimenti
- Il tutto va inviato come cartella compressa sulla pagina del corso su Moodle
  - il nome del file deve essere cognome-matricola.zip
  - In relazione e sorgenti indicate Nome, Cognome, Matricola