

# Campionamento di variabili aleatorie

- Andrea Marin  
Università Ca' Foscari Venezia
- Corso di Probabilità e Statistica a.a. 2009/2010

# Premessa

- Soluzione della prima esercitazione: l'analisi teorica
- Richiami: un esperimento consiste nel lancio di un dado equilibrato. Se il valore ottenuto è compreso tra 4 e 6, l'esito dell'esperimento è quel valore. Altrimenti si rilancia il dado e il valore ottenuto nell'esperimento è dato dalla somma del primo lancio e del secondo, in caso il totale sia minore o uguale di 6. Altrimenti il lancio non è valido

# Impostazione

Evento A: lancio primo dado con esito  $X_1 = 4, 5, 6$

Evento B: lancio secondo dado con esito tale che  $X_1 + X_2 \leq 6$  e  $X_1 \in \{1, 2, 3\}$

I due eventi sono disgiunti, per cui vale la relazione:

$$\Pr(A \cup B) = \Pr(A) + \Pr(B)$$

# Determinazione della probabilità di successo

- Chiaramente  $\Pr(A)=1/2$
- $\Pr(B)=\Pr(X_1+X_2 \leq 6 \mid X_1 \leq 3)\Pr(X_1 \leq 3)$
- Se  $X_1=1$ ,  $X_2$  può assumere valori 1,2,3,4,5
- Se  $X_1=2$ ,  $X_2$  può assumere valori 1,2,3,4
- Se  $X_1=3$ ,  $X_2$  può assumere valori 1,2,3
- $\Pr(X_1=1 \mid X_1 \leq 3) = 1/6 * 2 = 1/3$
- $\Pr(B) = (5+4+3) * 1/18 * 1/2 = 1/3$
- $\Pr(A \cup B) = 1/3 + 1/2 = 5/6$

# Determinazione della media degli eventi validi

- Definiamo la v.c.  $Y$  come segue:

$$Y = \begin{cases} X_1 & \text{se } 4 \leq X_1 \leq 6 \\ X_1 + X_2 & \text{se } 1 \leq X_1 \leq 3 \end{cases}$$

- La probabilità di  $y_i = 1/36, 2/36, 9/36, 9/36, 9/36, 3/36, 2/36, 1/36$  per  $i=2, \dots, 9$
- $\Pr(Y=i|Y \leq 6) = \Pr(Y \leq 6 | Y=i) \Pr(Y=i) / \Pr(Y \leq 6)$
- Questa espressione per  $i=2, 6$  vale  $\Pr(i) \cdot 6/5$ .
- Da cui calcoliamo la media:  $E(Y|Y \leq 6) = (2 \cdot 1 + 3 \cdot 2 + 4 \cdot 9 + 5 \cdot 9 + 6 \cdot 9) / 30 = 143/30$

# Definizione del problema

- Variabili casuali distribuite diversamente
- Il generatore di numeri casuali fornito con la maggior parte delle librerie/software è assimilabile ad un v.c. continua Uniforme nell'intervallo  $[0,1)$
- Problema: come possiamo generare v.c. (discrete o continue) con distribuzioni diverse da quella uniforme?

# Esempi già visti

- Problema già affrontato intuitivamente per casi semplici
- Generare un numero naturale casuale  $Y$  tra  $[2,6]$ :

$$X \sim \mathcal{U}[0, 1)$$

$$Y = \lfloor X * 5 \rfloor + 2$$

$$\Rightarrow Y \sim U[2, 6]$$

# La variabile di Bernoulli

- Sia  $p$  la probabilità che un evento si verifichi
- La v.c. di Bernoulli  $Y$  è definita come:

$$\Pr\{Y = 1\} = p \quad \Pr\{Y = 0\} = 1 - p$$

- Sia  $X$  una v.c. Aleatoria uniforme in  $[0,1)$
- Possiamo ottenere  $Y$  con la seguente trasformazione:
- $$Y = \mathbf{1}_{X > 1-p}$$
- Dove  $\mathbf{1}$  rappresenta la funzione indicatrice



# Generazione di v.c. continue

- Ipotesi di lavoro:

$X$  v.c. continua a valori in  $\mathbf{R}$

$$F_X(x) = \Pr\{X \leq x\}$$

- Com'è possibile generare campionamenti della v.c.  $X$  a partire dai campionamenti di una uniforme in  $[0,1)$ ?

# Un primo passo

- Data la v.c.  $X$  e la sua funzione di ripartizione  $F_X$  dimostriamo che la v.c.  $U$  definita come:

$$U = F_X(X)$$

- Ha distribuzione uniforme nell'intervallo  $[0,1]$

# Dimostrazione caso semplice

- Supponiamo  $F_X$  *strettamente* monotona crescente
- Dimostriamo  $F_U(u)=u$  assumendo  $0 \leq u \leq 1$

$$\begin{aligned} F_U(u) &= \Pr\{U \leq u\} = \Pr\{F_X(X) \leq u\} \\ &= \Pr\{X \leq F^{-1}(u)\} = F(F^{-1}(u)) = u \end{aligned}$$

I casi in cui  $u \notin [0,1]$  sono banali

# Caso generale


- $F_X(x)$  monotona crescente (non necessariamente strettamente)
- Definiamo:

$$F^{-1}(U) = \inf\{x : F(x) = u, 0 < u < 1\}$$

- Quindi possiamo procedere in modo analogo al precedente

# Metodo di inversione

- Campioniamo una v.c.  $U$  in  $[0,1)$
- Quindi poniamo:  
$$X = F^{-1}(U)$$
- $X$  è una v.c. continua la cui funzione di ripartizione è  $F$



# Esempio 1

- Generare una v.c. Uniforme nell'intervallo  $[3, 5]$
- In questo caso  $f_X(x) = 1/(5-3) = 1/2$  per  $3 \leq x \leq 5$  (0 altrove)

La funzione di ripartizione per  $3 \leq x \leq 5$  è:

$$F_X(x) = \int_{-\infty}^x f_X(z) dz = \left[ \frac{1}{2}u \right]_3^x = \frac{1}{2}x - \frac{3}{2}$$

- Applicando l'inversione:

$$F_X^{-1}(x) = 2u + 3$$

# Esempio 2

- Vogliamo campionare da una v.c.  $X$  distribuita in modo esponenziale con parametro  $\lambda$
- Funzione di ripartizione:

$$F_X(x) = \begin{cases} 1 - e^{-\lambda x} & \text{se } x \geq 0 \\ 0 & \text{altrimenti} \end{cases}$$

- Invertiamo per  $x > 0$ , ottenendo:

$$1 - e^{-\lambda x} = u \quad x = -\frac{1}{\lambda} \ln(1 - u)$$

# Esempio 2 (parte 2)

- Osserviamo che se  $U$  è una v.c. Uniforme in  $[0,1]$  così lo è anche  $1-U$ . Per cui possiamo scrivere:

$$X = -\frac{1}{\lambda} \log(U)$$



# Curiosità sull'esponenziale (Esempio del professore pigro)

- Un lampadario possiede due bulbi
- La durata dei bulbi è indipendente ed entrambe sono distribuite in modo esponenziale con parametro  $\lambda$
- Quando una delle due lampadine di brucia il professore pigro non la sostituisce ma le cambia entrambe quando sono entrambe rotte
- Supponiamo di voler determinare, per simulazione, per quanto tempo il professore sta con una sola lampadina

# Impostazione della simulazione

- Campioniamo la durata della prima lampadina  $X_1$
- Campioniamo la durata della seconda  $X_2$
- Il tempo  $T$  in cui il professore sta con con una sola lampadina è:

$$T = \max(X_1, X_2) - \min(X_1, X_2)$$

# Ricampionamento?

- Supponiamo di voler calcolare l'istante di tempo in cui si guasta la prima lampadina:

$$T_G = \min(X_1, X_2)$$


- A questo punto la vita residua della seconda lampadina è la v.c.  $Y$  la cui funz. di ripartizione è:

$$\Pr\{Y \leq y\} = \Pr\{X_i \leq y | X_i > T_G\}$$

- Com'è distribuita  $Y$ ? Possiamo ricampionare?

# Task (parte A) /1

- Si consideri una v.c. Continua la cui funzione di densità è illustrata in figura:



- Con il vincolo  $hw=2$

# Task (parte A) /2

- Formalmente la funzione di densità è:

$$f_X(x) = \begin{cases} (1 - x/w)h & 0 \leq x \leq w \\ 0 & \text{altrove} \end{cases}$$

- Scrivere in Matlab/Octave un generatore di numeri pseudo-casuali distribuiti secondo questa funzione di densità.
- Confrontare la funzione di ripartizione stimata con il campionamento con quella teorica.

# Campionamento di variabili casuali discrete

- Il metodo di inversione si applica anche a v.c. Discrete con un po' di attenzione...
- Consideriamo una v.c. Discreta  $X$  su  $m$  valori dove:

$$\Pr\{X = x_j\} = p_j, \quad \sum_{j=1}^m p_j = 1$$


$$F_k = \Pr(X \leq x_k) = \sum_{j=1}^k p_j$$

# Metodo di inversione

- Sia  $U$  una v.c. discreta in  $[0,1]$ , allora la v.c.  $X$  può essere definita come:

$$X = \begin{cases} x_1 & \text{se } U \leq F_1 \\ x_2 & \text{se } F_1 < U \leq F_2 \\ \vdots & \\ x_m & \text{se } F_{m-1} < U \leq F_m \end{cases}$$

# Intuizione grafica





# Campionamento della v.c. di Poisson per ricorsione

- Citazione: *If distributions were graded on a scale of one to ten, the Poisson clearly merits a ten.* [Taylor, Karlin]
- Perché tanta importanza?
  - Legge degli eventi rari
  - Alta trattabilità matematica

$$p_k = \frac{\lambda^k e^{-\lambda}}{k!} \quad k = 0, 1, \dots$$

# Generazione di v.c. Di Poisson per inversione

- Osserviamo la seguente relazione ricorsiva tra le probabilità:

$$p_0 = e^{-\lambda} \quad p_{i+1} = \frac{\lambda}{i+1} p_i$$

- Sia  $u$  il valore estratto dal generatore pseudo-causale
- Se  $u \leq F_i$  allora sarà estratto il valore  $i$
- Altrimenti calcoliamo  $p_{i+1}$  e  $F_{i+1} = F_i + p_{i+1}$  e ripetiamo il test del punto precedente

# Problemi del precedente approccio

- Funziona bene quando il parametro è grande (rispetto alla precisione numerica)
- In caso di parametri bassi possono esserci problemi di stabilità numerica (nel calcolo della funzione di ripartizione  $F_i$  )

# Richiami sulla v.c. geometrica

- Se  $p$  è la prob. di successo di un evento e  $(1-p)$  quella di insuccesso, la probabilità di  $k$  esperimenti indipendenti per ottenere il primo successo è:

$$p_X(k) = p(1 - p)^{k-1} \quad k = 1, 2, \dots$$

- La funzione di ripartizione è data da:

$$F_X(k) = \Pr\{X \leq k\} = \sum_{i=1}^k p(1 - p)^{i-1} = 1 - (1 - p)^k$$

# Generazione per definizione

```
K = 0;
```

```
do
```

```
    K = K + 1;
```

```
    U = rand;
```

```
Until (U > (1-p))
```

K è il numero estratto

# Generazione per inversione

- Invertiamo la funzione di ripartizione, sia  $q=1-p$

$$1 - q^k = u \Rightarrow q^k = 1 - u$$

$$k = \log_q(1 - u) = \frac{\log(1 - u)}{\log q}$$

$$k = \left\lfloor \frac{\log(u)}{\log(1 - p)} \right\rfloor + 1$$

# Task (parte B)

- Si vuole campionare la v.c. Binomiale in cui:

$$p_i = \binom{m}{i} p^i (1-p)^{m-i} \quad i = 1, 2, \dots, m$$

- Dopo aver stabilito una relazione ricorsiva tra  $p_{i+1}$  e  $p_i$  si implementi il campionamento per inversione
- Implementare il campionamento in base alla definizione di binomiale, ovvero contando il numero di successi su  $m$  esperimenti indipendenti di Bernoulli in cui un successo ha probabilità  $p$

# Task (Parte B)

- Confrontare le distribuzioni dei campionamenti (a parità di parametri devono dare la stessa distribuzione)
- Effettuare 20000 campionamenti di una variabile binomiale con parametri (8, 0.4) e stabilire quale delle due implementazioni è più efficiente (hint: usare il comando Octave `etime, clock`)