

## 21. Proprietà ergodica

Sia  $(X_n)_n$  una catena di Markov omogenea con spazio degli stati finito o numerabile. Supponiamo che la sua matrice di transizione  $\mathbf{P}$  sia irriducibile. Sia  $\bar{T}_{jj}$  il tempo di ritorno atteso nello stato  $j$  e sia  $V_j^{(n)}(x)$  il numero di visite nello stato  $j$  fatte dal cammino  $x$  nei primi  $n$  passi. In parole povere il *teorema ergodico* afferma che al crescere del numero di passi  $n$ , la frequenza delle visite nello stato  $j$  converge quasi certamente a  $\frac{1}{\bar{T}_{jj}}$ ,

$$\frac{V_j^{(n)}(x)}{n} \longrightarrow \frac{1}{\bar{T}_{jj}} \quad \mathbb{P}\text{-quasi certamente,}$$

vedi Paragrafo 21.b. Discutiamo quindi brevemente di una notevole e importante applicazione del teorema ergodico, nota come metodo catena di Markov Montecarlo, utile al calcolo approssimato iterato di integrali.

### 21.a Numero di passi tra due visite consecutive

Sia  $(X_n)_n$  una catena di Markov omogenea sullo spazio di probabilità  $(\Omega, \mathcal{E}, \mathbb{P})$  con spazio degli stati  $S$  finito o numerabile e sia  $j$  uno stato:  $j \in S$ . Siano  $\Omega_j := \{x \in \Omega \mid X_0(x) = j\}$  e  $\mathbb{P}_j(A) := \mathbb{P}(A \mid X_0 = j)$ ,  $A \in \mathcal{E}$  la misura di probabilità condizionata da  $X_0 = j$ . Indichiamo con  $f_{ij}$  la probabilità di visitare  $j$  partendo da  $i$  e con  $\bar{T}_{jj}$  il tempo medio di ritorno in  $j$ .

A partire dalla successione dei tempi di passaggio  $(T_j^{(r)})_r$  in  $j$ , vedi (20.8), possiamo definire le variabili aleatorie  $(S_j^{(r)}(x))_r$ ,  $r = 1, 2, \dots$ , dove  $S_j^{(1)} = T_j^{(1)}$  e, per  $r \geq 2$ ,

$$S_j^{(r)}(x) := \begin{cases} T_j^{(r)}(x) - T_j^{(r-1)}(x) & \text{se } T_j^{(r-1)}(x) < +\infty, \\ +\infty & \text{altrimenti.} \end{cases}$$

Ciascuna variabile aleatoria  $S_j^{(r)}(x)$  conta il numero di passi tra la visita  $(r-1)$ -esima e la visita  $r$ -esima nello stato  $j$ .

**21.1 Teorema.** *Sia  $j \in S$  uno stato ricorrente e sia  $i \in S$  tale che  $f_{ij} = 1$ . Allora*

- (i)  $S_j^{(r)}(x)$  è finito per quasi ogni  $x \in \Omega_i$  e per ogni  $r \geq 1$ .
- (ii)  $\left(S_j^{(r)}\right)_r$  è una successione di variabili aleatorie indipendenti rispetto alla probabilità  $\mathbb{P}_i$ .
- (iii) Le variabili aleatorie  $S_j^{(r)}$ ,  $r \geq 2$ , sono identicamente distribuite rispetto alla probabilità  $\mathbb{P}_i$  e, per ogni  $n \geq 1$  e  $r \geq 2$ ,

$$\mathbb{P}_i(S_j^{(r)} = n) = f_{jj}^{(n)} \quad \text{e} \quad \mathbb{E}_i \left[ S_j^{(r)} \right] = \bar{T}_{jj}.$$

*Dimostrazione.* (i) Poiché  $j$  è ricorrente, ogni cammino da  $i$  visita  $j$  infinite volte con probabilità  $f_{ij}$ ,

$$\mathbb{P} \left( T_j^{(r)} < \infty \mid X_0 = i \right) = f_{ij} = 1 \quad \forall r \geq 1,$$

vedi Proposizione 20.5. Dunque per ogni  $r \geq 2$ ,  $T_j^{(r)}(x) < +\infty$  per q.o.  $x \in \Omega_i$ . In particolare,  $1 \leq S_j^{(r)}(x) < +\infty$  per quasi ogni  $x \in \Omega_i$ . Quindi

$$\mathbb{P}_i(S_j^{(r)} = +\infty) = 0.$$

(ii) Siano  $r \geq 2$ ,  $h_1, \dots, h_{r-1} \geq 1$ ,  $h = (h_1, \dots, h_{r-1}) \in \mathbb{N}^{r-1}$  e  $n \geq 1$ . Poniamo  $k := h_1 + \dots + h_{r-1}$  e siano  $T(x) := T_j^{(r-1)}(x)$  e

$$H_h := \left\{ x \in \Omega \mid S_j^{(r-1)}(x) = h_{r-1}, S_j^{(r-2)}(x) = h_{r-2}, \dots, S_j^{(1)}(x) = h_1 \right\}.$$

L'evento  $H_h$  è rilevato dalle variabili aleatorie  $X_0, \dots, X_k$  e  $H_h = \{x \in \Omega \mid X_k = j\} \cap F_h$  dove  $F_h$  è rilevato da  $X_0, \dots, X_{k-1}$ . Si ha

$$\mathbb{P}_i \left( S_j^{(r)} = n \mid H_h \right) = \frac{\mathbb{P} \left( \{S_j^{(r)} = n\} \cap H_h \mid X_0 = i \right)}{\mathbb{P} \left( H_h \mid X_0 = i \right)}$$

e poiché

$$\begin{aligned} & \left\{ x \in \Omega \mid S_j^{(r)} = n \right\} \cap H_h \\ &= \left\{ x \in \Omega \mid X_{n+k} = j, X_{n+k-1} \neq j, \dots, X_{k-1} \neq j, X_k = j \right\} \cap H_h \end{aligned}$$

si ha, ricordando che  $H_h = \{x \in \Omega \mid X_k = j\} \cap F_h$  e utilizzando la proprietà di Markov e l'omogeneità della catena

$$\begin{aligned}
 & \mathbb{P} \left( \{S_j^{(r)} = n\} \cap H_h \mid X_0 = i \right) \\
 &= \mathbb{P} \left( X_{n+k} = j, X_{n+k-1} \neq j, \dots, X_{k-1} \neq j \mid \{X_k = j\} \cap F_h \right) \\
 &\quad \cdot \mathbb{P} \left( H_h \mid X_0 = i \right) \\
 &= \mathbb{P} \left( X_n = j, X_{n-1} \neq j, \dots, X_1 \neq j \mid \{X_0 = j\} \cap F_h \right) \\
 &\quad \cdot \mathbb{P} \left( H_h \mid X_0 = i \right) \\
 &= f_{jj}^{(n)} \mathbb{P} \left( H_h \mid X_0 = i \right).
 \end{aligned}$$

Ne segue che per ogni  $r \geq 2$

$$\mathbb{P}_i \left( S_j^{(r)} = n \mid H_h \right) = f_{jj}^{(n)}.$$

In particolare gli eventi individuati da  $S_j^{(r)}$  sono indipendenti dagli eventi  $H_h$ ,  $h \in \mathbb{N}^{r-1}$ , cioè indipendenti dagli eventi individuati da  $S_j^{(r-1)}, \dots, S_j^{(1)}$ . Dunque  $S_j^{(r)}$  è indipendente da  $S_j^{(r-1)}, \dots, S_j^{(1)}$  e, poiché  $r$  è arbitrario,  $(S_j^{(r)})_r$  è una successione di variabili aleatorie indipendenti rispetto alla misura  $\mathbb{P}_i$ .

(iii) Poiché gli  $H_h$  sono a due a due disgiunti e

$$\bigcup_{h \in \mathbb{N}^{r-1}} H_h = \left\{ x \in \Omega \mid S_j^{(r)} < +\infty \right\},$$

$\sum_{h \in \mathbb{N}^{r-1}} \mathbb{P}_i(H_h) = 1$ . Pertanto da (ii) segue per ogni  $r \geq 2$  e ogni  $n \geq 1$

$$\mathbb{P}_i(S_j^{(r)} = n) = \sum_h \mathbb{P}_i \left( S_j^{(r)} = n \mid H_h \right) \mathbb{P}_i(H_h) = f_{jj}^{(n)} \sum_{h \in \mathbb{N}^{r-1}} \mathbb{P}_i(H_h) = f_{jj}^{(n)} :$$

le variabili  $(S_j^{(r)})_{r \geq 2}$  sono identicamente distribuite rispetto a  $\mathbb{P}_i$ . Infine,

$$\mathbb{E}_i \left[ S_j^{(r)} \right] = \sum_{k=0}^{\infty} k \mathbb{P}_i(S_j^{(r)} = k) = \sum_{k=1}^{\infty} k f_{jj}^{(k)} = \bar{T}_{jj}.$$

□

## 21.b Teorema ergodico

**21.2 Proposizione.** *Sia  $(X_n)_n$  una catena di Markov omogenea con spazio degli stati  $S$  finito o numerabile. Per ogni  $j \in S$  sia  $\bar{T}_{jj}$  il tempo medio di ritorno in  $j$  e  $w_j = 1/\bar{T}_{jj}$ . Siano  $i, j \in S$ ,  $\Omega_i := \{x \in \Omega \mid X_0(x) = i\}$  e  $\mathbb{P}_i(A) := \mathbb{P}(A \mid \Omega_i)$ . Se*

$j$  è transiente o se  $j$  è ricorrente e  $f_{ij} = 1$ , allora la frequenza delle visite in  $j$  nei primi  $n$  passi,  $\frac{V_j^{(n)}(x)}{n}$ , converge a  $w_j$  per q.o.  $x \in \Omega_i$ , i.e.,

$$\frac{V_j^{(n)}(x)}{n} \rightarrow w_j \quad \mathbb{P}_i\text{-quasi ovunque.} \quad (21.1)$$

*Dimostrazione.* Se lo stato  $j$  è transiente, per (20.16)  $w_j = 0$  e i cammini da  $i$  quasi certamente visitano  $j$  solo un numero finito di volte, vedi Proposizione 17.7. Dunque

$$\frac{V_j^{(n)}(x)}{n} \leq \frac{V_j(x)}{n} \rightarrow 0 = w_j \quad \mathbb{P}\text{-quasi certamente.}$$

Se lo stato  $j$  è ricorrente e  $f_{ij} = 1$ , si applica il Teorema 21.1. Con le notazioni del Teorema 21.1, le variabili aleatorie  $S_j^{(r)}$ ,  $r \geq 2$ , sono indipendenti ed identicamente distribuite rispetto alla probabilità  $\mathbb{P}_i$  con  $\mathbb{E}_i[S_j^{(r)}] = \bar{T}_{jj} \in \overline{\mathbb{R}}_+$ . Pertanto dalla legge dei grandi numeri, vedi Esercizio 14.23,

$$\frac{1}{n} \sum_{r=1}^n S_j^{(r)}(x) \rightarrow \bar{T}_{jj} \quad \mathbb{P}_i\text{-quasi certamente.}$$

Poiché per  $n \geq T_j^{(1)}(x) + S_j^{(2)}(x) = T_j^{(2)}(x)$

$$V_j^{(n)}(x) = \sup \left\{ k \geq 2 \mid \sum_{r=2}^k S_j^{(r)}(x) \leq n \right\},$$

segue dalla Proposizione 15.8 che

$$\frac{V_j^{(n)}(x)}{n} \rightarrow \frac{1}{\bar{T}_{jj}} = w_j \quad \mathbb{P}_i\text{-quasi certamente.}$$

□

**21.3 Teorema (Teorema ergodico).** Sia  $(X_n)_n$  una catena di Markov omogenea con spazio degli stati  $S$  finito o numerabile e con matrice di transizione  $\mathbf{P}$  irriducibile. Per ogni  $j \in S$  siano  $\bar{T}_{jj}$  il tempo medio di ritorno in  $j$  e  $w_j = 1/\bar{T}_{jj}$ . Allora

(i) Si ha

$$\frac{V_j^{(n)}(x)}{n} \rightarrow w_j \quad \mathbb{P}\text{-quasi certamente.} \quad (21.2)$$

(ii) Sia  $\phi : S \rightarrow \mathbb{R}$  una funzione tale che  $\sum_{j \in S} |\phi(j)| < \infty$ . Allora

$$\frac{1}{n} \sum_{k=1}^n \phi(X_k) \rightarrow \sum_{j \in S} \phi(j) w_j \quad \mathbb{P}\text{-quasi certamente.} \quad (21.3)$$

*Dimostrazione.* (i) Gli stati di  $S$  o sono tutti ricorrenti o sono tutti transienti e, se  $j \in S$  è ricorrente, allora  $f_{ij} = 1$ , vedi Proposizione 20.5. Pertanto dalla Proposizione 21.2 per ogni  $i \in S$ ,  $\frac{V_j^{(n)}(x)}{n} \rightarrow w_j$  quasi certamente in  $\Omega_i := \{x \in \Omega \mid X_0(x) = i\}$ , quindi  $\frac{V_j^{(n)}(x)}{n} \rightarrow w_j$  per  $\mathbb{P}$ -quasi ogni  $x \in \Omega$ .

(ii) Per  $j \in S$  e  $k \geq 1$ , sia  $E_{j,k} := \{x \in \Omega \mid X_k(x) = j\}$ . Poiché

$$V_j^{(n)}(x) = \sum_{k=1}^n \mathbb{1}_{E_{j,k}}(x) \quad \text{e} \quad \phi(X_k(x)) = \sum_{j \in S} \phi(j) \mathbb{1}_{E_{j,k}}(x)$$

si ha

$$\begin{aligned} \frac{1}{n} \sum_{k=1}^n \phi(X_k(x)) &= \frac{1}{n} \sum_{k=1}^n \left( \sum_{j \in S} \phi(j) \mathbb{1}_{E_{j,k}}(x) \right) \\ &= \sum_{j \in S} \phi(j) \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{E_{j,k}}(x) = \sum_{j \in S} \phi(j) \frac{V_j^{(n)}(x)}{n}. \end{aligned}$$

Poiché  $\sum_{j \in S} |\phi(j)| < \infty$ , si può passare al limite con il teorema di convergenza dominata Esempio C.12, e ottenere

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n \phi(X_k(x)) &= \lim_{n \rightarrow \infty} \sum_{j \in S} \phi(j) \frac{V_j^{(n)}(x)}{n} = \sum_{j \in S} \phi(j) \left( \lim_{n \rightarrow \infty} \frac{V_j^{(n)}(x)}{n} \right) \\ &= \sum_{j \in S} \phi(j) w_j \quad \mathbb{P}\text{-quasi certamente.} \end{aligned}$$

□

**21.4 Teorema.** Sia  $(X_n)_n$  una catena di Markov omogenea con spazio degli stati  $S$  finito o numerabile e con matrice di transizione  $\mathbf{P}$ . Per ogni  $j \in S$  sia  $\bar{T}_{jj}$  il tempo medio di ritorno in  $j$  e  $w_j = 1/\bar{T}_{jj}$ . Per ogni  $i, j \in S$  si ha

$$\frac{1}{n} \sum_{k=1}^n p_{jj}^{(k)} \rightarrow w_j, \quad \frac{1}{n} \sum_{k=1}^n p_{ij}^{(k)} \rightarrow f_{ij} w_j. \quad (21.4)$$

Se  $\mathbf{P}$  è irriducibile, allora

$$\frac{1}{n} \sum_{k=1}^n p_{ij}^{(k)} \rightarrow w_j. \quad (21.5)$$

*Dimostrazione.* Dalla Proposizione 21.2 segue in particolare che  $\frac{V_j^{(n)}(x)}{n} - w_j \rightarrow 0$   $\mathbb{P}_j$ -quasi certamente. Inoltre  $\frac{V_j^{(n)}(x)}{n} \leq 1$ . Si applica il teorema di convergenza dominata, Teorema C.10, e si ottiene che

$$\int_{\Omega_j} \left| \frac{V_j^{(n)}(x)}{n} - w_j \right| \mathbb{P}(dx) \rightarrow 0,$$

in particolare

$$\mathbb{E}_j \left[ V_j^{(n)} \right] = \frac{1}{\mathbb{P}(X_0 = j)} \int_{\{X_0 = j\}} \frac{V_j^{(n)}(x)}{n} \mathbb{P}(dx) \rightarrow w_j$$

e quindi la prima delle (21.4), poiché

$$\frac{1}{n} \sum_{k=1}^n p_{jj}^{(k)} = \mathbb{E}_j \left[ \frac{V_j^{(n)}}{n} \right].$$

La seconda delle (21.4) segue quindi dal Lemma 20.12.

Infine se  $\mathbf{P}$  è irriducibile, allora la (21.5) segue dalla (21.4) poiché  $w_j = 0$  se  $j$  è transiente e  $f_{ij} = 1$  se  $j$  è ricorrente, vedi Proposizione 20.5.  $\square$

**21.5 Corollario.** Sia  $(X_n)_n$  una catena di Markov omogenea con spazio degli stati  $S = \{1, \dots, N\}$  finito e con matrice di transizione  $\mathbf{P}$  irriducibile. Per ogni  $j \in S$  sia  $\bar{T}_{jj}$  il tempo medio di ritorno in  $j$  e  $w_j = 1/\bar{T}_{jj}$ . Allora

$$\frac{1}{n} \sum_{k=1}^n p_{ij}^{(k)} \rightarrow w_j,$$

$w := (w_1, \dots, w_N)$  è l'unico vettore stocastico soluzione di  $w = w\mathbf{P}$  e  $w_j > 0 \forall j$ , i.e., ogni stato è positivamente ricorrente.

*Dimostrazione.* Segue dal Teorema 21.4, dalla Proposizione 18.15 e dall'Esercizio 18.19.  $\square$

### 21.c Catena di Markov Monte Carlo

In molte applicazioni è necessario valutare la *somma pesata*, rispetto ad un peso  $\pi = (\pi_j)$ , di una certa quantità  $f: S \rightarrow \mathbb{R}$  definita su un insieme finito  $S$

$$E := \frac{1}{z} \sum_{j \in S} f(j) \pi_j, \quad z := \sum_{j \in S} \pi_j. \quad (21.6)$$

Usando il linguaggio della probabilità, indichiamo con  $\mu$  la probabilità su  $S$  con densità discreta  $\frac{1}{z}(\pi_j)_{j \in S}$ . La quantità da valutare dunque non è altro che

$$E := \int_S f(t) \mu(dt). \quad (21.7)$$

Se l'insieme  $S$  è piccolo, allora è possibile calcolare  $E$  direttamente. Se  $S$  è “grande”, (per esempio  $|E| = (50)!$ ), allora il calcolo di  $E$  o anche solo della massa totale  $z$  non può essere effettuato direttamente. È perciò opportuno avere almeno una strategia per calcolare, o quantomeno approssimare, il valore di  $E$ .

### 21.d Monte Carlo

Una di queste strategie è il cosiddetto metodo Monte Carlo, vedi Paragrafo 15.b. Si deve specificare uno spazio di probabilità  $(\Omega, \mathcal{E}, \mathbb{P})$  e una variabile aleatoria  $X : \Omega \rightarrow S$  con distribuzione  $\mathbb{P}_X = \mu$ ; si considera poi lo schema di Bernoulli delle successioni a valori in  $\Omega$ ,  $(\Omega^\infty, \mathcal{E}^\infty, \mathbb{P}^\infty)$ , e le variabili aleatorie  $X_n : \Omega^\infty \rightarrow \mathbb{R}$  definite, per ogni  $n = 1, 2, \dots$ , e  $x = (x_n)_n \in \Omega^\infty$ , come  $X_n(x) := X(x_n)$ . Le  $X_n$  costituiscono una successione di variabili aleatorie indipendenti ed identicamente distribuite come  $X$ ,  $\mathbb{P}_{X_n} = \mathbb{P}_X = \mu$ , vedi Corollario 13.22. La legge forte dei grandi numeri afferma che, per quasi ogni successione di punti  $x = (x_n)_n, x_n \in \Omega$ ,

$$\frac{1}{n} \sum_{j=1}^n f(X(x_j)) = \frac{1}{n} \sum_{j=1}^n f(X_j(x)) \rightarrow E \quad (21.8)$$

e vale la stima debole (14.3).

Per tradurre questo risultato in un algoritmo è necessario affrontare due questioni:

- (i) Come scegliere (il più efficacemente possibile) lo spazio di probabilità  $(\Omega, \mathcal{E}, \mathbb{P})$  e la variabile aleatoria  $X : \Omega \rightarrow S$  avente distribuzione  $\mathbb{P}_X = \mu$ ;
- (ii) Poiché il limite (21.8) è vero solo per quasi ogni successione  $(x_k)_k \in \Omega^\infty$  (e non per ogni successione), bisogna assicurarsi di selezionare una successione “buona”. Il “rischio” di selezionare una “cattiva” successione è zero e tuttavia le “cattive” successioni esistono.

Se nella successione è presente una qualche forma di periodicità (o di regolarità), questa può influenzare il valore del limite o la sua stessa esistenza. Per esempio, supponiamo di lanciare una moneta equa infinite volte. Se si ottiene un successo (testa) ad ogni lancio o una volta ogni tre lanci, allora  $\frac{1}{n} \sum_{k=1}^n X_k(x) = \frac{1}{x} \sum_{k=1}^n X(x_k)$  converge a 1 nel primo caso e a  $1/3$  nel secondo e non al valore atteso  $1/2$ . Dovremmo metterci nelle condizioni di selezionare una successione il più possibile “irregolare” o “casuale”.

Esistono molti modi per ottenere successioni o, meglio, vettori di “grande dimensione” di numeri casuali uniformemente distribuiti sull’intervallo  $[0, 1]$ . È necessario essere cauti con la terminologia poiché questi numeri sono in realtà multipli interi di un numero fisso molto “piccolo”. Tuttavia, se  $f$  non è una funzione fortemente oscillante e se l’approssimazione non deve essere estremamente accurata, questo fatto non crea problemi. Per esempio, *generatori fisici di numeri casuali* possono essere basati su fenomeni fisici atomici o subatomici la cui casualità è data dalle leggi della meccanica quantistica, quali il decadimento radioattivo, il rumore termico e altri. Con opportuni condizionamenti questi fenomeni sono sorgenti di campioni casuali uniformemente distribuiti sull’intervallo  $[0, 1]$ .

Un’altra fonte utile sono i *generatori di numeri pseudo-casuali*. Si tratta di algoritmi deterministici che possono generare lunghe sequenze di numeri con “buone” proprietà stocastiche. Una casualità completa è fuori questione in quanto l’output di questi algoritmi è dato da sequenze periodiche, sebbene di periodo

molto lungo. Inoltre le correlazioni tra output di indici molto diversi o tra gruppi di output vanno accuratamente controllate. Esistono comunque librerie di software che contengono generatori pseudo-casuali con proprietà statistiche certificate. Non ci occupiamo di questi aspetti che sono comunque rilevanti nel campo delle simulazioni, vedi per esempio [22], ma che non riguardano strettamente la probabilità. Per proseguire questa discussione, assumeremo che esistano generatori di “successioni casuali” uniformemente distribuite sull’intervallo  $[0, 1]$  e che sia possibile raggrupparli in  $N$ -uple in modo da ottenere una successione di  $N$ -uple uniformemente distribuite su  $Q = [0, 1]^N$ .

Sulla base delle considerazioni precedenti, scelte tipiche per  $(\Omega, \mathcal{E}, \mathbb{P})$  e  $X$  per il calcolo di  $E$  nell’equazione (21.7) per  $\mu = \mathcal{L}^N$  sono  $(Q, \mathcal{B}(\mathbb{R}^N), \mathcal{L}^N)$  e  $X(x) := x$ .

Approssimare l’integrale (21.7) mediante la procedura (21.8) quando la misura  $\mu$  non è uniforme, è cosa più complessa. Diamo un accenno alla procedura nel caso scalare. Supponiamo di voler calcolare

$$E := \int_{-\infty}^{+\infty} f(t) d\mu(t)$$

con  $f$  funzione limitata e di Borel e  $(\mathcal{B}(\mathbb{R}), \mu)$  misura su  $\mathbb{R}$ . Per prima cosa ci procuriamo una variabile aleatoria  $X$  con distribuzione  $\mu$ . Per questo, si considera la legge  $F(t) := \mu(\cdot - \infty, t]$  di  $\mu$  e si definisce la variabile aleatoria  $X : [0, 1] \rightarrow \mathbb{R}$  sullo spazio probabilizzato  $([0, 1], \mathcal{B}(\mathbb{R}), \mathcal{L}^1)$  come nella (9.13), cioè si pone

$$X(s) := \min \{t \mid s \leq F(t)\}. \quad (21.9)$$

Poiché  $F(t)$  è continua da destra, la  $X(s)$  è continua da sinistra e dunque è di Borel. Inoltre  $\{s \in [0, 1] \mid X(s) \leq t\} = \{s \in [0, 1] \mid 0 \leq s \leq F(t)\}$  per ogni  $t \in \mathbb{R}$  e dunque

$$\mathcal{L}^1(X \leq t) = \mathcal{L}^1([0, F(t)]) = F(t) \quad \forall t \in \mathbb{R},$$

cioè la distribuzione di  $X$  è  $\mu$ . Pertanto il metodo Monte Carlo afferma che per quasi ogni successione  $(x_k)_k$  in  $[0, 1]$  “distribuita uniformemente” in  $[0, 1]$

$$\frac{1}{n} \sum_{k=1}^n f(X(x_k)) \rightarrow \int_{-\infty}^{+\infty} f(t) \mu(dt) \quad \text{per } n \rightarrow \infty.$$

La procedura ora descritta non può essere implementata per valutare (21.6) quando l’insieme  $S$  è grande, poiché il calcolo della legge  $F(t) := \mu(\cdot - \infty, t]$  di  $\mu$  o della variabile aleatoria  $X$  definita in (21.9) sono dello stesso ordine di complessità del calcolo diretto di  $E$ .

Quando l’insieme  $S$  può essere visto come un prodotto cartesiano,  $S = S_1 \times \dots \times S_N$  e la misura  $\mu$  con densità di massa  $\frac{1}{z}(\pi_j)$  è un prodotto,

$$\mu = \mu_1 \times \mu_2 \times \dots \times \mu_N$$

dove ciascuna  $\mu_i$  è una misura su  $S_i$ , è possibile fattorizzare il calcolo di  $X$ . Per esempio, se  $N = 2$ , definiamo due variabile aleatorie  $X : [0, 1] \rightarrow S_1$ ,  $Y : [0, 1] \rightarrow S_2$  che seguono, rispettivamente, le distribuzioni  $\mu_1$  e  $\mu_2$ . Allora

$$\begin{aligned} \int f(t,s) \mu_1 \times \mu_2(dt ds) &= \int \left( \int f(t,s) \mu_2(ds) \right) \mu_1(dt) \\ &= \int \left( \int f(t, Y(y)) \mathbb{P}(dy) \right) \mu_1(dt) = \iint g(X(x), Y(y)) \mathbb{P} \times \mathbb{P}(dx dy), \end{aligned}$$

cosicché la legge forte dei grandi numeri dà

$$\frac{1}{n} \sum_{k=1}^n f(X(x_k), Y(y_k)) \rightarrow E$$

per quasi ogni successione  $((x_k, y_k))_k$  di punti in  $[0, 1]^2$ .

### 21.e Il metodo della catena di Markov Monte Carlo

Se  $\mu$  non è una misura prodotto, è possibile sfruttare la proprietà ergodica delle catene di Markov.

Il paradigma che seguiamo per il calcolo di  $E$  nella (21.6) è il seguente: data la densità di probabilità  $w = (w_j)_{j \in S}$ ,  $w_j := \frac{1}{z} \pi_j$ , definiamo una catena di Markov omogenea su uno spazio di probabilità  $(\Omega, \mathcal{E}, \mathbb{P})$  con spazio degli stati  $S$  e tale che  $w$  sia un punto fisso per la sua matrice di transizione  $\mathbf{P}$ ,  $w = w\mathbf{P}$ , cioè tale che  $\pi = \pi\mathbf{P}$ .

Abbiamo già provato, vedi Teorema 19.9, che data una matrice stocastica  $\mathbf{P}$  è sempre possibile definire una catena di Markov omogenea con matrice di transizione  $\mathbf{P}$ . Resta dunque da esibire una matrice stocastica  $\mathbf{P}$  per la quale  $\pi$  sia un punto fisso: l'*algoritmo di Hastings–Metropolis* fornisce una matrice con questa proprietà.

Sia  $\mathbf{Q} = (q_{ij})$  una matrice stocastica. Per  $i, j \in S$ ,  $i \neq j$ , sia

$$p_{ij} := \frac{1}{\pi_i} \min\{\pi_i q_{ij}, \pi_j q_{ji}\}, \quad (21.10)$$

cosicché  $0 \leq p_{ij} \leq 1$  e  $\sum_{j \neq i} p_{ij} \leq 1$ . Definiamo  $\mathbf{P} = (p_{ij})$  come segue:

- se  $i \neq j$ , allora  $p_{ij}$  è definita dalla (21.10)
- se  $i = j$ , poniamo  $p_{ii} = 1 - \sum_{j \neq i} p_{ij}$ ,

di modo che  $\mathbf{P}$  è una matrice stocastica. La matrice  $\mathbf{R} = (r_{ij})$ ,

$$r_{ij} := \min\{\pi_i q_{ij}, \pi_j q_{ji}\}$$

è simmetrica quindi

$$\pi_i p_{ij} = \pi_j p_{ji} \quad \forall i, j \in S$$

e

$$\sum_{i=1}^N \pi_i p_{ij} = \sum_{i=1}^N \pi_j p_{ji} = \pi_j \quad \forall j \in S$$

cioè  $\pi = \pi\mathbf{P}$ .

Nell'*algoritmo di Metropolis* si sceglie una matrice  $\mathbf{Q} = (q_{ij})$  irriducibile e simmetrica, e per  $i \neq j$  si pone

$$p_{ij} = \min \left\{ 1, \frac{\pi_j}{\pi_i} \right\} q_{ij},$$

e si definisce  $\mathbf{P} = (p_{ij})$  come

$$p_{ij} = \begin{cases} q_{ij} & \text{se } \pi_j/\pi_i > 1, \\ \frac{\pi_j}{\pi_i} q_{ij} & \text{se } \pi_j < \pi_i, \\ 1 - \sum_{j \neq i} p_{ij} & \text{se } i = j. \end{cases} \quad (21.11)$$

Possibili scelte per la matrice  $\mathbf{Q}$  sono

$$q_{ij} = \begin{cases} 1/(N-1) & \text{se } i \neq j, \\ 0 & \text{se } i = j, \end{cases}$$

dove  $N = |S|$ , o, per esempio si può scegliere come  $\mathbf{Q}$  la matrice associata ad una passeggiata aleatoria simmetrica circolare. Osserviamo che in generale, per definire  $\mathbf{P}$  non è necessario conoscere la massa totale  $z$  o la cardinalità  $N$  di  $S$ .

Sia  $(X_n)_n$  una catena di Markov omogenea con matrice di transizione  $\mathbf{P}$ , vedi Teorema 19.9. Se  $\mathbf{P}$  è *irriducibile*, allora  $\frac{1}{z}\pi$  è l'unico vettore stocastico che è punto fisso di  $P(x) = x\mathbf{P}$ . Inoltre, per ogni  $j \in S$  il numero  $(\frac{1}{z}\pi_j)^{-1}$  è il tempo di ritorno in  $j$  per la catena  $(X_n)_n$ , vedi Corollario 21.5. Il teorema ergodico, (ii) del Teorema 21.3, assicura la convergenza

$$\frac{1}{n} \sum_{k=1}^n f(X_k(x)) \rightarrow \frac{1}{z} \sum_{j \in S} f(j)\pi_j = E$$

per quasi ogni  $x \in \Omega$ .

Per simulare la catena è sufficiente avere un ampio numero di variabili aleatorie indipendenti che seguono la distribuzione uniforme in  $[0, 1]$ , vedi Teorema 19.9, perciò questa procedura, conosciuta come *catena di Markov Monte Carlo* può condurre ad algoritmi numerici per il calcolo approssimato di  $E$ , vedi, per esempio, [21].

La simulazione di una catena di Markov con matrice di transizione  $\mathbf{P}$  consiste nella transizione da una posizione  $i \in S$  al passo  $n$  in una nuova posizione  $j$  al passo  $(n+1)$  seguendo la densità di probabilità  $(p_{ij})_j$ . In questo caso

$$p_{ij} = \min \left\{ 1, \frac{\pi_j}{\pi_i} \right\} q_{ij}.$$

Si procede dunque nel modo seguente: supponiamo di essere nello stato  $i$  al passo  $n$ . Selezioniamo  $j \in S$  seguendo la densità di massa  $(q_{ij})_j$ . Allora

- se  $\pi_i \leq \pi_j$  ci spostiamo nello stato  $j$ ,  $X_{n+1} = j$ ;

- se  $\pi_i > \pi_j$  effettuiamo un esperimento di Bernoulli con parametro  $p = \pi_j/\pi_i$ . Si pone  $X_{n+1} = j$  se si ottiene un successo e  $X_{n+1} = i$  altrimenti.

Due fatti sono cruciali per le applicazioni numeriche. Innanzitutto va verificato che la matrice  $\mathbf{P}$  sia irriducibile, cosa che si può verificare per molte applicazioni del metodo. Il secondo punto cruciale è ovviamente il numero di passi necessari per ottenere una stima di  $E$  con l'accuratezza desiderata. Non ci occuperemo di queste questioni che coinvolgono stime sia statistiche che analitiche e che sono ancora un campo di ricerca aperto.

Invitiamo il lettore alla lettura di [21] e dell'articolo [9] in cui sono presentate ulteriori applicazioni, quali problemi di ottimizzazione, del metodo della catena di Markov Monte Carlo. Qui presentiamo solo il seguente risultato, vedi [5].

**21.6 Teorema (Metropolis et al.).** *Se  $\pi$  non è costante e se la matrice  $\mathbf{P}$  definita nella (21.11) dell'algoritmo di Metropolis è irriducibile, allora  $\mathbf{P}$  è regolare.*

*Dimostrazione.* Dimostriamo che esiste  $h \in S$  tale che  $p_{hh} > 0$ . Sia  $C := \{i \mid \pi_i = \max_j \pi_j\}$ . Ovviamente,  $C \neq \emptyset$  e, per ipotesi,  $C \neq S$ . Quindi, vedi Esercizio 18.18, esistono  $h \in C$  e  $k \notin C$  tale che  $q_{hk} > 0$  e  $\pi_h > \pi_k$ . Se  $i \neq j$ , allora  $p_{ij} \leq q_{ij}$ , e per definizione di  $\mathbf{P}$

$$\begin{aligned} p_{hh} &= 1 - \sum_{j \neq h} p_{hj} = 1 - \sum_{j \neq h, k} p_{hj} - p_{hk} \\ &\geq 1 - \sum_{j \neq h, k} q_{hj} - \frac{\pi_k}{\pi_h} q_{hk} = 1 - \sum_{j \neq h} q_{hj} + q_{hk} \left(1 - \frac{\pi_k}{\pi_h}\right) \\ &= q_{hh} + q_{hk} \left(1 - \frac{\pi_k}{\pi_h}\right) > 0. \end{aligned}$$

La tesi segue dall'Esercizio 17.16. □