

# 馬可夫隨機場簡介

## 依佛

近幾年利用隨機場 (random field) 來考慮影像處理還頗成功。將影像的性質，例如亮度、顏色等，看成是圖 (graph) 的位置 (site) 上的隨機狀態；而位置間的關係則由圖的邊 (edge) 來表示。馬可夫隨機場 (Markov random field) 提供這種空間 (spatial) 過程一個自然的架構。它和 Gibbs 分布的等價性不但使得在模型建構和統計推論時更具彈性，且可和統計物理關聯起來。而利用馬可夫性質和隨機 relaxation (或蒙地卡羅方法) 可以部分地解決此類模式先天上的解析困難。這是它在應用上成功的原因之一。

本文舉統計物理上有名的 Ising 模式來描述馬可夫隨機場及一些相關的性質。

### Ising 模式

$S = \{(i, j) : 1 \leq i, j \leq N\}$  為  $N \times N$  的格子。對每一格子點  $s \in S$ ，令  $\mathcal{G}_s$  表示  $s$  的鄰居， $\Lambda_s$  表示在  $s$  點的狀態所成的集合。這裡

$$\mathcal{G}_{i,j} = \{(i-1, j), (i+1, j), (i, j-1), (i, j+1)\} \cap S,$$

$$\Lambda_{i,j} = \{-1, +1\}.$$

又令

$\Omega$  是所有影像所成的集合，即

$$\Omega = \{x : x = (x_s)_{s \in S}, x_s \in \Lambda_s\},$$

相鄰的格子點  $s, t$  以  $\langle s, t \rangle$  表示，即

$$s \in \mathcal{G}_t (\sim t \in \mathcal{G}_s).$$

定義

$$H(x) = -\frac{k}{T} \sum_s x_s - \frac{J}{T} \sum_{\langle s, t \rangle} x_s x_t, \quad (1)$$

其中  $k, J, T$  是參數。

利用  $H$  我們在  $\Omega$  上定義一機率  $P$ ，

$$\begin{aligned} P(x) &= Z^{-1} \exp -H(x), \\ Z &= \sum_{y \in \Omega} \exp -H(y). \end{aligned} \quad (2)$$

若  $-1, +1$  分別表示白色及黑色，則參數  $k, J, T$  決定後， $P(x)$  便是  $x$  這黑白影像出現的機率。

$P$  的形式看起來很單純，但實際要算出  $Z$  是個大問題，更不必說直接從  $P$  抽樣。問題出在  $\Omega$  有  $2^{N^2}$  個元素，對  $64 \times 64$  的格子，這

已是天文數字。比較可行的方法是用隨機 relaxation 或蒙地卡羅法, 也就是造出一馬可夫鏈, 使得此鏈的極限為  $P$ 。然後利用此鏈來逼近我們所要計算的值。

令  $X_s(x) = x_s$ , 則

$$P(X_s = x_s | X_r = x_r, r \neq s) = P(X_s = x_s | X_r = x_r, r \in \mathcal{G}_s). \quad (3)$$

此式就是馬可夫隨機場的意思: 給  $s$  位置以外的資料和只給  $s$  的鄰居的資料所做出的條件機率是一樣的。此條件機率的計算非常簡單; 注意,  $Z$  自動會被消掉。利用 (3) 可定有名的 Gibbs Sampler。

給定  $x_r$  在  $s$  位置的變化由下述的隨機矩陣決定:

$$P_s(x, y) = P(X_s = y_s | X_r = x_r, r \neq s), \\ \text{假如 } y_r = x_r, \forall r \neq s; \quad (4) \\ = 0, \text{其他。}$$

**Random Gibbs sampler:**任取一位置  $s$ , 然後以  $P_s$  為隨機矩陣選下一步的影像, 所對應的隨機矩陣為

$$\frac{1}{|S|} \sum_s P_s, \quad (5)$$

$|S|$  表  $S$  的元素個數。

**Systematic Gibbs sampler:** 將  $S$  中的位置排序, 然後依序在每個位置做更新, 這所對應的隨機矩陣為

$$P_{s_1} P_{s_2} \dots P_{s_{|S|}}. \quad (6)$$

當然也可同時在幾個位置上做改變, 或考慮其他方法, 我們不在本文討論。

不論起始影像, Gibbs sampler 的馬可夫鏈的極限恆為 (2) 的  $P$ 。

現回到較一般的情形。假設  $S$  和  $\Lambda_s, s \in S$  都是有限集合。任一定義在  $\Omega$  上的機率  $P$  且  $P(x) > 0, \forall x \in \Omega$ , 則  $P$  可由 (3) 式左邊的條件機率唯一決定。

我們需定義鄰居系統  $\mathcal{G}_s, s \in S$  以便討論馬可夫隨機場: 對每一  $s, \mathcal{G}_s \subseteq S, s \notin \mathcal{G}_s$  且  $s \in \mathcal{G}_t$  若且唯若  $t \in \mathcal{G}_s$ 。

$P$  是鄰居系統  $\mathcal{G}_s, s \in S$ , 的一馬可夫隨機場的定義就是 (3) 式。

$\Omega$  上的任一正的機率一定是鄰居系統  $\mathcal{G}_s = S - \{s\}$  的馬可夫隨機場, 但以計算的觀點來看, 這樣的系統不實用。我們要的是  $|\mathcal{G}_s| \ll |S|$ 。例如上述的 Ising 模式,  $|\mathcal{G}_s| \leq 4$ 。

對  $\mathcal{G}_s, s \in S$ , 定義

$$\mathcal{C} = \{C | C \subseteq S, C \text{ 爲一單點或對 } C \text{ 中任兩相異點 } s, t, s \in \mathcal{G}_t\}.$$

再以 Ising 模式為例,  $C \in \mathcal{C}$  則  $C = \{s\}, s \in S$  或  $C = \{s, t\}, s, t$  爲相鄰兩格子點。

機率  $P$  稱爲對  $\mathcal{G}_s, s \in S$  的 Gibbs 分布, 假如  $P$  可寫成 (2) 的型式且

$$H(x) = - \sum_{c \in \mathcal{C}} V_c(x),$$

$V_c(x)$  具有:  $V_c(x) = V_c(y)$  若  $x_s = y_s, s \in C$ , 的性質。也就是說  $V_c(x)$  的值由  $x_s, s \in C$  決定。Ising 模式所對應的 (1) 式的  $H$  就是這型式。

$P$  為  $\mathcal{G}$  - 馬可夫隨機場和  $P$  為  $\mathcal{G}$  - Gibbs 分布是對等的關係。

我們同樣可用 (4) 來定義 Gibbs sampler。因 (3) 式成立, 若  $|\mathcal{G}_s|$  不大, 計算應不難。

本文簡介至此, 有興趣者請看

D. Geman (1990), Random fields

and inverse problems in imaging,  
Lecture Notes in Mathematics Vol.  
1427, 113-193, Springer-Verlag,  
及其中的參考資料。

—本文作者任職於中央研究院數學研究所—