

機率論基礎

第一節 基礎定義

在這個章節，我們將定義並且討論在機率論中最基本的概念，包含機率空間、隨機變數、期望值、特徵函數等等。

機率論可以被視為測度論的特例，也就是說當測度總質量為有限或者為 1 的情況，所以在第一章中複習過的很多概念以及定理，在機率論中還是有效的。此外，從機率論的角度來看，機率空間本身並不是這麼重要，我們感興趣的是隨機變數可以取的值，以及這些值出現的頻率。

在機率論以及測度論中的不同概念有下列對應：

機率空間	$\longleftrightarrow$	測度空間
事件	$\longleftrightarrow$	σ 代數中的元素
隨機變數	$\longleftrightarrow$	可測函數
期望值	$\longleftrightarrow$	積分

再來我們會將上述不同名詞給出明確的定義，以及提供不同例子。

第一小節 機率空間

我們在第 1.1 節中回顧了測度空間的定義，在機率論中，我們需要定義的機率空間其實只是它的一個特例。

定義 2.1.1：令 $(\Omega, \mathcal{A})$ 為一個可測空間，且令 $\mathbb{P}$ 為一個在 $(\Omega, \mathcal{A})$ 之上總質量為 1 的測度，稱作機率測度 (probability measure)，那麼我們將 $(\Omega, \mathcal{A}, \mathbb{P})$ 稱為一個機率空間 (probability space)。

- 集合 Ω 稱作樣本空間 (sample space)，可以視為隨機試驗中，描述「隨機單位」的空間。
- 集合 $\mathcal{A}$ 包含了所有的可測事件，也可以簡稱做事件，也就是所有 Ω 可以被「機率」所測量的子集合。換句話說，元素 $A \in \mathcal{A}$ 是個 Ω 的子集合，其中包含了所有滿足特定條件的「隨機單位」。
- 對於任何 $A \in \mathcal{A}$ ， $\mathbb{P}(A)$ 描述可測事件 A 發生的機率。
- 若樣本空間 Ω 為離散（有限或可數無限），則我們可以考慮 $\mathcal{A} = \mathcal{P}(\Omega)$ ，並將任何定義在可測空間 $(\Omega, \mathcal{A})$ 上的機率測度 $\mathbb{P}$ 稱作離散機率 (discrete probability)，機率空間 $(\Omega, \mathcal{A}, \mathbb{P})$ 則稱作離散機率空間 (discrete probability space)。

範例 2.1.2 【離散機率空間】： 給定一顆六面數字分別為 1 至 6 的公正骰子。

- (1) 考慮骰子丟兩次的機率實驗，那麼我們可以令機率空間為 $\Omega = \{1, \dots, 6\}^2$ ，可以測量的事件集合為 $\mathcal{A} = \mathcal{P}(\Omega)$ ，機率測度 $\mathbb{P}$ 則有下列性質：對於任何 $A \in \mathcal{A}$ ，我們有 $\mathbb{P}(A) = \frac{|A|}{36}$ 。
- (2) 考慮一顆不公正的銅板，其出現正面的機率是反面的兩倍，考慮投擲此銅板三次的實驗，那麼我們可以令機率空間為

$$\Omega = \{(\text{正}, \text{正}, \text{正}), (\text{正}, \text{正}, \text{反}), (\text{正}, \text{反}, \text{正}), (\text{正}, \text{反}, \text{反}), \\ (\text{反}, \text{正}, \text{正}), (\text{反}, \text{正}, \text{反}), (\text{反}, \text{反}, \text{正}), (\text{反}, \text{反}, \text{反})\},$$

可以測量的事件集合為 $\mathcal{A} = \mathcal{P}(\Omega)$ ，機率測度 $\mathbb{P}$ 則有下列性質：若對於任何 $\omega \in \Omega$ ，我們記正面及反面出現次數為 $H(\omega)$ 及 $T(\omega)$ ，那麼我們有 $\mathbb{P}(\omega) = (\frac{2}{3})^{H(\omega)}(\frac{1}{3})^{T(\omega)}$ 。

範例 2.1.3 【一般機率空間】： 平面上的單位圓可以記作

$$\mathbb{S}^1 := \{z \in \mathbb{C} : |z| = 1\} \simeq \mathbb{R}/(2\pi\mathbb{Z}),$$

且可以詮釋為二維空間中的單位方向。若我們考慮可測空間 $(\mathbb{S}^1, \mathcal{B}(\mathbb{S}^1))$ 及機率測度

$$\mathbb{P}([a, b]) = \frac{b - a}{2\pi}, \quad a \leq b, |b - a| \leq 2\pi$$

則 $\mathbb{P}$ 會是個在 $\mathbb{S}^1 = \mathbb{R}/(2\pi\mathbb{Z})$ 上的均勻機率。這也可以視為由在 $\mathbb{R}$ 上的勒貝格測度「引導」出來在商空間 $\mathbb{S}^1$ 上的（機率）測度。

第二小節 隨機變數

在機率論中，其實機率空間本身顯得並沒有這麼重要，因為我們感興趣的是在隨機試驗中，可以觀察且測量的量，以及這些不同結果發生的頻率。因此，我們在下面定義隨機變數的概念，並將它視為「在一個隨機試驗中，隨機單位事件給出的結果」。

定義 2.1.4： 令 $(\Omega, \mathcal{A}, \mathbb{P})$ 為機率空間及 $(E, \mathcal{E})$ 為可測空間，則我們稱可測函數 $X : \Omega \rightarrow E$ 為取值在 E 中的隨機變數 (random variable)。

範例 2.1.5： 我們取上章節範例 2.1.2 中的機率空間，並考慮在上面定義的隨機變數。

- (1) 定義 $X((i, j)) = i + j$ ，那麼 X 是個值域為 $\{2, \dots, 12\}$ 的隨機變數。
- (2) 定義 $H(\omega)$ 為「在 ω 之中，正面出現的次數」，那麼 H 是個值域為 $\{0, 1, 2, 3\}$ 的隨機變

數。

範例 2.1.6：考慮範例 2.1.3 定義的機率空間，並考慮隨機變數

$$X(\omega) = \cos(\omega), \quad Y(\omega) = \sin(\omega), \quad \forall \omega \in \mathbb{S}^1.$$

則隨機變數 X 及 Y 取值在 $[-1, 1]$ 之中並可被視為均勻隨機方向在 x 軸及 y 軸上的投影。

隨機變數 $X : \Omega \rightarrow E$ 的定義域（也就是機率空間）本身並沒這麼重要，我們比較在意的是它的值域，也就是說，他取不同值的機率。換句話說，我們想要理解機率測度 $\mathbb{P}$ 在 X 函數作用下的影像測度。

定義 2.1.7：定義 $\mathbb{P}_X$ 為測度 $\mathbb{P}$ 在隨機變數 X 之下的影像測度 (image measure)，我們稱之為隨機變數 X 的分佈 (distribution) 或是律 (law)。換句話說， $\mathbb{P}_X$ 是個在可測空間 $(E, \mathcal{E})$ 之上的機率測度，可以寫作

$$\mathbb{P}_X(B) := \mathbb{P}(X^{-1}(B)), \quad \forall B \in \mathcal{E}.$$

在機率論的語言中，通常我們也會將上述縮寫為

$$\mathbb{P}_X(B) = \mathbb{P}(X \in B) = \mathbb{P}(\omega \in \Omega : X(\omega) \in B), \quad \forall B \in \mathcal{E}.$$




圖 2.1: 描述影像測度 $\mathbb{P}_X$ 的示意圖，此影像測度也可以看作為機率測度 $\mathbb{P}$ 透過隨機變數 X 向前推進 (pushforward) 所得到的測度，也記作 $X_*\mathbb{P}$ 。我們真正在意的會是機率測度 $\mathbb{P}_X$ 而不是 $\mathbb{P}$ 。

我們應該以下面方式來理解影像測度：對於任意機率空間中的一點 $\omega \in \Omega$ ， $X(\omega)$ 是個在 E 中的點，那麼 $\mathbb{P}_X(B)$ 則表示這個隨機點在 B 中的機率。

範例 2.1.8 : 令 $(\Omega, \mathcal{A}, \mathbb{P})$ 為機率空間，其中 $\Omega = [0, \pi]$ 、 $\mathcal{A}$ 是伯雷爾 σ 代數，以及 $\mathbb{P} = \frac{1}{\pi}\lambda$ 。考慮隨機變數 $X : (\Omega, \mathcal{A}, \mathbb{P}) \rightarrow \mathbb{R}$ 定義做：

$$X(\omega) = \sin(\omega), \quad \omega \in \Omega = [0, \pi].$$

影像測度 $\mathbb{P}_X$ 是定義在可測空間 $([0, 1], \mathcal{B}([0, 1]))$ 上。我們可以透過 $\mathbb{P}_X([a, b])$ 對於所有 $0 \leq a \leq b \leq 1$ 的值，來刻劃這個影像測度。對於 $0 \leq a \leq b \leq 1$ ，我們有

$$\begin{aligned} \mathbb{P}_X([a, b]) &= \mathbb{P}(\omega \in \Omega : \sin(\omega) \in [a, b]) \\ &= \mathbb{P}(\omega \in \Omega : \omega \in [\sin^{-1} a, \sin^{-1} b]) + \mathbb{P}(\omega \in \Omega : \omega \in [\pi - \sin^{-1} b, \pi - \sin^{-1} a]) \\ &= \frac{2}{\pi}(\sin^{-1} b - \sin^{-1} a). \end{aligned}$$

註解 2.1.9 : 若隨機變數 $X : (\Omega_1, \mathcal{A}_1, \mathbb{P}_1) \rightarrow (E, \mathcal{E})$ 及 $Y : (\Omega_2, \mathcal{A}_2, \mathbb{P}_2) \rightarrow (E, \mathcal{E})$ 有相同的分佈，也就是說 $\mathbb{P}_{1,X} := X_*\mathbb{P}_1 = Y_*\mathbb{P}_2 =: \mathbb{P}_{2,Y}$ ，則我們可以記作

$$X \stackrel{(d)}{=} Y \quad \text{或} \quad X \sim Y \quad \text{或} \quad X \sim \mathbb{P}_{2,Y}.$$

若我們要說隨機變數 X 的分佈是 μ ，也就是說 $\mathbb{P}_{1,X} = \mu$ ，則我們也可以記作

$$X \sim \mu,$$

並說 X 遵從 μ 的分佈。

註解 2.1.10 : 在 $(E, \mathcal{E}) = (\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ 的情況下， $\mathbb{P}_X$ 是個在 $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ 上的機率測度，若他對 $\mathbb{R}^d$ 上的勒貝格測度 λ 絕對連續，則根據 Radon-Nikodym 定理（定理 1.3.16），我們知道存在密度函數 $g : \mathbb{R}^d \rightarrow \mathbb{R}_+$ 使得我們可以將 $\mathbb{P}_X$ 寫作 $\mathbb{P}_X = g \cdot \lambda$ 。我們稱 g 為隨機變數 X 的機率密度函數 (probability density function)。

註解 2.1.11 【隨機變數的正則構造】 : 若 μ 是個在 $\mathbb{R}^d$ 上的機率測度，我們可以用下列方式來構造一個分佈為 μ 的隨機變數：取 $\Omega = \mathbb{R}^d$ ， $\mathcal{A} = \mathcal{B}(\mathbb{R}^d)$ ， $\mathbb{P} = \mu$ 並且令 $X(\omega) = \omega$ ，我們可以檢查 X 的分佈是 μ 。稍後在命題 2.1.23 中，當我們給定 $\mathbb{R}$ 上的機率測度 μ 時，我們會看到該如何從均勻測度出發，來構造分佈為 μ 的實數隨機變數。

第三小節 期望值

有了隨機變數之後，第一個重要的量是其期望值。

定義 2.1.12：令 X 為一值域為 $\mathbb{R}$ 的隨機變數（也稱為實隨機變數），在下列情況下：

- X 非負；
- X 可取正負值，且 $\int |X| d\mathbb{P} < \infty$ ，

我們可以定義其期望值 (expectation)，並記作

$$\mathbb{E}[X] = \int_{\Omega} X(\omega) \mathbb{P}(d\omega). \quad (2.1)$$

若 $X = (X_1, \dots, X_d)$ 是個 d 維的實隨機變數（也就是其值域為 $\mathbb{R}^d$ ），若所有的期望值 $\mathbb{E}[X_i]$ 都是有定義的，我們可以定義 X 的期望值為 $\mathbb{E}[X] = (\mathbb{E}[X_1], \dots, \mathbb{E}[X_d])$ 。

註解 2.1.13：令 B 為一可測子集以及 $X = \mathbb{1}_B$ ，則 $\mathbb{E}[X] = \mathbb{P}(B)$ 。一般來講，我們可以將 $\mathbb{E}[X]$ 視為隨機變數 X 的「平均值」，例如在 Ω 為有限集合，且 $\mathbb{P}$ 為均勻分佈的情況下， $\mathbb{E}[X]$ 代表的是 X 所有可能取的值的（加權）平均值。

命題 2.1.14：令 X 為一值域為 $(E, \mathcal{E})$ 的隨機變數，則對於任何可測函數 $f: E \rightarrow [0, \infty]$ ，我們有

$$\mathbb{E}[f(X)] = \int_E f(x) \mathbb{P}_X(dx).$$

證明：我們首先證明對於任意可測集合 $B \in \mathcal{E}$ ，指標函數 $f = \mathbb{1}_B$ 滿足此式，接著透過線性組合，證明對於所有的非負簡單函數皆為真。再來，由於非負可測函數可以寫作非負簡單函數序列的非遞減極限（命題 1.2.14），根據單調收斂定理，得證。 $\square$

註解 2.1.15：若 f 不恆正，只要期望值 $\mathbb{E}[|f(X)|]$ 是有限的，上述命題依然為真。不要忘記可取正負值的一般函數，他的積分也是以相同方式定義的，請見定義 1.2.18。

註解 2.1.16：機率分佈 $\mathbb{P}_X$ 可以讓我們輕易計算 $f(X)$ 類型的隨機變數的期望值。反過來看，對於任意可測集合 $B \in \mathcal{E}$ ，若我們考慮 $f = \mathbb{1}_B$ ，則 $\mathbb{E}[f(X)] = \mathbb{P}(X \in B) = \mathbb{P}_X(B)$ 。不要忘記，機率測度 $\mathbb{P}_X$ 是定義在 $\mathcal{E}$ 上的，也就是說，如果我們知道 $(\mathbb{P}_X(B))_{B \in \mathcal{E}}$ ，則此機率測度是被唯一決定的。換句話說，若是我們有辦法對「夠多的」可測函數 f 寫出下列式子

$$\mathbb{E}[f(X)] = \int f d\nu, \quad (2.2)$$

則透過上面的討論，我們知道隨機變數 X 的分佈會是被機率測度 ν 所描述的。在實際操作上，我們可以對所有非負可測函數，或是在 $\mathcal{C}_c(\mathbb{R}^d)$ 中所有的函數來計算式 (2.2)。

範例 2.1.17：我們考慮與範例 2.1.8 中相同的範例，並且比較兩邊的計算。回顧 $(\Omega, \mathcal{A}, \mathbb{P})$ 是個機率空間，其中 $\Omega = [0, \pi]$ 、 $\mathcal{A}$ 是伯雷爾 σ 代數，以及 $\mathbb{P} = \frac{1}{\pi} \lambda$ 。隨機變數 $X : (\Omega, \mathcal{A}, \mathbb{P}) \rightarrow \mathbb{R}$ 定義做：

$$X(\omega) = \sin(\omega), \quad \omega \in \Omega = [0, \pi].$$

我們可以透過對於所有非負可測函數 $f : \mathbb{R} \rightarrow \mathbb{R}$ ，計算 $\mathbb{E}[f(X)]$ 的值，來刻劃 X 的分佈。對於非負可測函數 $f : \mathbb{R} \rightarrow \mathbb{R}$ ，我們記

$$\begin{aligned} \mathbb{E}[f(X)] &= \mathbb{E}[f(X(\omega))] = \frac{1}{\pi} \int_0^\pi f(\sin \omega) \, d\omega \\ &= \frac{2}{\pi} \int_0^{\pi/2} f(\sin \omega) \, d\omega \\ &= \frac{2}{\pi} \int_0^1 f(x) \frac{dx}{\sqrt{1-x^2}}, \end{aligned}$$

其中在第二行，我們使用積分項在 $\omega \mapsto \pi - \omega$ 下的對稱性；在第三行，我們使用變數變換 $x = \sin \omega$ 。這代表著，影像測度 $\mathbb{P}_X$ 寫做：

$$\mathbb{P}_X(dx) = \frac{2}{\pi} \frac{dx}{\sqrt{1-x^2}}.$$

這是個對於勒貝格測度來說，是絕對連續的測度，他的密度函數為 $x \mapsto \frac{2}{\pi} \frac{1}{\sqrt{1-x^2}}$ 。

下列命題給我們一個重要的例子，來幫助理解這樣的概念。

命題 2.1.18：令 $(X_1, \dots, X_d)$ 為一值域為 $\mathbb{R}^d$ 的隨機變數。假設其機率密度函數為 $p(x_1, \dots, x_d)$ ，則對於任何 $1 \leq j \leq d$ ，隨機變數 X_j 的機率密度函數也存在，且可以寫作

$$p_j(x) = \int_{\mathbb{R}^{d-1}} p(x_1, \dots, x_{j-1}, x, x_{j+1}, \dots, x_d) \, dx_1 \dots dx_{j-1} \, dx_{j+1} \dots dx_d.$$

註解 2.1.19：考慮一個二維隨機變數的情況下 ($d = 2$)，我們有

$$p_1(x) = \int_{\mathbb{R}} p(x, y) \, dy, \quad p_2(y) = \int_{\mathbb{R}} p(x, y) \, dx.$$

證明：令 π_j 為對於 j 座標的投影： $\pi_j(x_1, \dots, x_d) = x_j$ ，對於所有非負可測函數 $f: \mathbb{R} \rightarrow \mathbb{R}_+$ ，我們可以使用富比尼定理：

$$\begin{aligned}\mathbb{E}[f(X_j)] &= \mathbb{E}[f(\pi_j(X))] = \int_{\mathbb{R}^d} f(x_j) p(x_1, \dots, x_d) dx_1 \dots dx_d \\ &= \int_{\mathbb{R}} f(x_j) \left(\int_{\mathbb{R}^{d-1}} p(x_1, \dots, x_d) dx_1 \dots dx_{j-1} dx_{j+1} \dots dx_d \right) dx_j \\ &= \int_{\mathbb{R}} f(x_j) p_j(x_j) dx_j. \quad \square\end{aligned}$$

註解 2.1.20：若 $X = (X_1, \dots, X_d)$ 是個值域 d 維的實隨機變數，我們稱 X_j 的分佈為邊緣分佈 (marginal distribution)，並記為 $\mathbb{P}_{X_j}$ 。根據上述命題，我們可以輕易得到 $\mathbb{P}_{X_j} = (\pi_j)_* \mathbb{P}_X$ ，也就是說，從 X 的分佈我們可以輕易求得任意 X_j 的分佈。需要知道的是，若我們知道所有的邊緣分佈 $\mathbb{P}_{X_j}$ ，我們是無法找回 X 的分佈的。

問題 2.1.21：試著構造兩個二維的實隨機變數 $X = (X_1, X_2)$ 及 $X' = (X'_1, X'_2)$ 使得對於 $j = 1, 2$ ， X_j 及 X'_j 有著相同的邊緣分佈，但 X 及 X' 的分佈卻不相同。

第四小節 累積分佈函數

定義 2.1.22：令 X 為一實隨機變數，我們定義函數 $F_X: \mathbb{R} \rightarrow [0, 1]$ 為

$$F_X(t) = \mathbb{P}(X \leq t) = \mathbb{P}_X((-\infty, t]), \quad t \in \mathbb{R}.$$

我們稱他為隨機變數 X 的累積分佈函數 (cumulative distribution function)，記作 c.d.f.，也可以稱作分佈函數 (distribution function)。

我們提醒在定理 1.2.29 中有看到， F_X 是個非遞減、右連續，且在 $-\infty$ 及 $+\infty$ 的極限分別為 0 及 1 的函數。此外我們知道，逆命題也成立，也就是說如果 F 是個滿足上列條件的函數，則我們可以找到唯一的機率測度 μ 使得對於所有 $t \in \mathbb{R}$ ，我們有 $F(t) = \mu((-\infty, t])$ 。也就是說 F 是個實隨機變數的累積分佈函數。

此外，累積分佈函數 F_X 也可以完整描述隨機變數 X 的分佈 $\mathbb{P}_X$ ，其中我們有：

$$\begin{aligned}\mathbb{P}(a \leq X \leq b) &= F_X(b) - F_X(a-), & a \leq b, \\ \mathbb{P}(a < X < b) &= F_X(b-) - F_X(a), & a < b,\end{aligned}$$

且 F_X 中的不連續點為 $\mathbb{P}_X$ 的原子。

第二章 機率論基礎

若 $X := (X_1, \dots, X_d)$ 是個取值在 $\mathbb{R}^d$ 中的隨機變數，我們也能夠以類似的方式來討論上面的概念。對於所有 $(t_1, \dots, t_d) \in \mathbb{R}^d$ ，我們可以定義

$$F_X(t_1, \dots, t_d) := \mathbb{P}(X_1 \leq t_1, \dots, X_d \leq t_d) = \mathbb{P}_X((-\infty, t_1] \times \dots \times (-\infty, t_d]).$$

命題 2.1.23： 令 $F : \mathbb{R} \rightarrow [0, 1]$ 是個非遞減、右連續，且在 $-\infty$ 及 $+\infty$ 的極限分別為 0 及 1 的函數。定義函數 $h : (0, 1) \rightarrow \mathbb{R}$ 為

$$h(y) := \inf\{z \in \mathbb{R} : F(z) \geq y\}, \quad \forall y \in (0, 1). \quad (2.3)$$

若 Y 是個隨機變數使得 $\mathbb{P}_Y$ 的分佈與 $[0, 1]$ 上勒貝格測度相同，則隨機變數 $h(Y)$ 的分配函數會是 F ，也就是說 $F_{h(Y)} = F$ 。

註解 2.1.24： 在此命題的敘述中，我們注意到，若 F 是個雙射函數（也就是嚴格遞增），則我們有 $h = F^{-1}$ 。

證明： 固定 $y \in (0, 1)$ 及 $x \in \mathbb{R}$ 。若 $F(x) \geq y$ ，根據 h 的定義，我們可以得到 $x \geq h(y)$ 。反過來，若 $F(x) < y$ ，使用 F 的右連續性，我們可以找到 $\varepsilon > 0$ 使得 $F(x + \varepsilon) < y$ ，再根據單調性，對於所有 $z \leq x + \varepsilon$ ，我們會有 $F(z) < y$ ，因此 $h(y) \geq x + \varepsilon > x$ 。因此，我們有下列的等價關係：

$$x \geq h(y) \Leftrightarrow F(x) \geq y.$$

令 Y 為隨機變數使得 $\mathbb{P}_Y$ 是在 $[0, 1]$ 上的勒貝格測度，以及 $Z := h(Y)$ 。我們注意到，根據命題 1.2.2， Z 也會是一個隨機變數。由於 $\mathbb{P}(Y \in (0, 1)) = 1$ ，我們有

$$F_Z(x) = \mathbb{P}(h(Y) \leq x) = \mathbb{P}(Y \leq F(x)) = F_Y(F(x)) = F(x). \quad \square$$

註解 2.1.25： 從命題 2.1.23，我們得知若均勻隨機變數存在（這是我們的假設，也是測度論會去構造的東西，這裡不深入討論），則對於任何在 $\mathbb{R}$ 上給定的分佈，我們可以透過他的分佈函數來構造有此分佈的實隨機變數。

第二節 隨機變數的生成 σ 代數

令 $(E, \mathcal{E})$ 為一可測空間。

定義 2.2.1：若 $X : (\Omega, \mathcal{A}) \rightarrow (E, \mathcal{E})$ 為隨機變數，我們可以定義 $\sigma(X)$ 為 $\mathcal{A}$ 最小的子 σ 代數，使得 X 是可測的，我們稱之為由 X 生成的 σ 代數：

$$\sigma(X) = \{A = X^{-1}(B) : B \in \mathcal{E}\}.$$

註解 2.2.2：我們可以將 $\sigma(X)$ 視為需要能夠正確描述隨機變數 X 的最小的 σ 代數。

範例 2.2.3：固定機率空間 $(\Omega, \mathcal{A}, \mathbb{P})$ 並考慮隨機變數 $X : (\Omega, \mathcal{A}, \mathbb{P}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$ 。

- (1) 若隨機變數 X 取值恆為常數，則 $\sigma(X) = \{\emptyset, \Omega\}$ 為平凡 σ 代數。
- (2) 給定可測集合 $A \in \mathcal{A}$ ，若隨機變數 X 寫作 $X = \mathbb{1}_A$ ，則 $\sigma(X) = \{\emptyset, A, A^c, \Omega\}$ 。
- (3) 若隨機變數 X 只會取 0 及 1 兩個值，則存在 $A \in \mathcal{A}$ 使得 $X = \mathbb{1}_A$ ，因此 $\sigma(X)$ 的描述與上面情況像同。
- (4) 我們不難驗證，對於任意 $A, B \in \mathcal{A}$ 滿足 $A \notin \{\emptyset, B, B^c, \Omega\}$ ，隨機變數 $\mathbb{1}_A$ 並不會是 $\sigma(\mathbb{1}_B)$ 可測的，我們看到在樣本空間上選擇不同的 σ 代數，也會造成隨機變數的概念改變。

範例 2.2.4：考慮機率空間 $(\Omega, \mathcal{A}, \mathbb{P}) := ([0, 2), \mathcal{B}([0, 2)), \frac{1}{2}\lambda)$ ，其中 λ 為勒貝格測度。我們定義隨機變數 $X, Y : (\Omega, \mathcal{A}, \mathbb{P}) \rightarrow ([0, 2), \mathcal{B}([0, 2)))$ 做 $X(\omega) = \omega$ 及 $Y(\omega) = \lfloor \omega \rfloor$ ，則

$$\sigma(X) = \mathcal{B}([0, 2)), \quad \text{且} \quad \sigma(Y) = \{\emptyset, [0, 1), [1, 2), [0, 2)\}.$$

我們可以注意到 $([0, 2), \sigma(Y), \mathbb{P})$ 可以被視為一個離散機率空間：定義

$$\Omega' := \{0, 1\}, \quad \mathcal{A}' := \{\emptyset, \{0\}, \{1\}, \{0, 1\}\}, \quad \text{且} \quad \mathbb{P}' := \frac{1}{2}\delta_0 + \frac{1}{2}\delta_1,$$

則 $(\Omega, \mathcal{A}, \mathbb{P})$ 與 $(\Omega', \mathcal{A}', \mathbb{P}')$ 有相同的結構。

註解 2.2.5：我們可以將這個定義拓展到任意集合的隨機變數 $X = (X_i)_{i \in I}$ 。假設對任意 $i \in I$ ， X_i 的值域為 $(E_i, \mathcal{E}_i)$ ，我們可以定義

$$\sigma(X) = \sigma(X_i^{-1}(B_i) : B_i \in \mathcal{E}_i, i \in I).$$

命題 2.2.6：令 X 為值域在 $(E, \mathcal{E})$ 中的隨機變數， Y 為實隨機變數，則下列性質等價：

- (1) Y 對 $\sigma(X)$ 可測。

(2) 存在一可測函數 $f : (E, \mathcal{E}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$ 使得 $Y = f(X)$ 。

證明：根據命題 1.2.2，若 (2) 成立，則 (1) 成立。

假設 Y 對 $\sigma(X)$ 是可測的，我們想要證明 (2)。首先處理當 Y 為簡單函數的狀況：對於 $i \in \{1, \dots, n\}$ ，令 $\lambda_i \in \mathbb{R}$ 以及 $A_i \in \sigma(X)$ ，且 Y 寫作

$$Y = \sum_{i=1}^n \lambda_i \mathbb{1}_{A_i}.$$

對於所有 $i \in \{1, \dots, n\}$ ，我們可以找到 $B_i \in \mathcal{E}$ 使得 $A_i = X^{-1}(B_i)$ ，所以 Y 可以重新寫作

$$Y = \sum_{i=1}^n \lambda_i \mathbb{1}_{A_i} = \sum_{i=1}^n \lambda_i \mathbb{1}_{B_i} \circ X = f \circ X,$$

其中 $f = \sum_{i=1}^n \lambda_i \mathbb{1}_{B_i}$ 是個對於 $\mathcal{E}$ 可測的函數。

在一般情況下，存在對 $\sigma(X)$ 可測的簡單函數序列 (Y_n) 使得 Y_n 簡單收斂至 Y (命題 1.2.14)，因此根據此證明前半部所述，對於所有 n ，我們可以找到可測函數 $f_n : E \rightarrow \mathbb{R}$ 使得 $Y_n = f_n(X)$ 。對於所有 $x \in E$ ，我們可以設

$$f(x) = \begin{cases} \lim_{n \rightarrow \infty} f_n(x) & \text{如果極限存在,} \\ 0 & \text{其他情況.} \end{cases}$$

根據命題 1.2.6，函數 f 仍然為可測。此外，我們注意到，對於所有 $\omega \in \Omega$ ，我們有

$$\lim_{n \rightarrow \infty} f_n(X(\omega)) = \lim_{n \rightarrow \infty} Y_n(\omega) = Y(\omega).$$

若 $x = X(\omega)$ ，則在上面的定義中， $\lim_{n \rightarrow \infty} f_n(x)$ 的極限是存在的，而且我們有

$$f(X(\omega)) = \lim_{n \rightarrow \infty} f_n(X(\omega)) = Y(\omega),$$

也就是說 $Y = f(X)$ 。

□

第三節 常用機率分佈

在這章節中，我們介紹一些常用的隨機變數分佈。

在第 2.3.1 小節中，我們會刻劃兩種類別的機率分佈：離散分佈以及絕對連續分佈。在第 2.3.2 小節中，我們給出常用的離散隨機變數分佈的例子，在第 2.3.3 小節中我們給出常用的絕對連續隨機變數的例子。

第一小節 機率分佈的分類

我們這裡探討兩個不同類型的隨機變數：離散型隨機變數以及絕對連續型隨機變數。

令 $(\Omega, \mathcal{A}, \mathbb{P})$ 為一機率空間且 $(E, \mathcal{E})$ 為一可測空間，考慮一個值域為 E 的隨機變數 $X : \Omega \rightarrow E$ 。

定義 2.3.1 【離散型隨機變數】： 當 E 為一可數集合，且 $\mathcal{E} = \mathcal{P}(E)$ 時， X 的分佈可以寫作

$$\mathbb{P}_X = \sum_{x \in E} p_x \delta_x,$$

其中 $p_x = \mathbb{P}(X = x)$ ， δ_x 代表的是在 x 的狄拉克測度。上述式子可以透過下列式子來理解：

$$\mathbb{P}_X(B) = \mathbb{P}(X \in B) = \mathbb{P}\left(\bigcup_{x \in B} \{X = x\}\right) = \sum_{x \in B} \mathbb{P}(X = x) = \sum_{x \in E} p_x \delta_x(B).$$

從上述性質可以得知，如果想要知道一離散隨機變數 X 的分佈，我們需要知道的是對於所有 $x \in E$ ，機率 $\mathbb{P}(X = x)$ 的值。

當機率空間不為離散時，我們這裡只討論下面的情況，也就是可以定義密度函數的情況。

定義 2.3.2 【絕對連續型隨機變數】： 假設 $(E, \mathcal{E}) = (\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ ，若 $\mathbb{P}_X$ 對於勒貝格測度 λ 是絕對連續的話，我們說 $\mathbb{P}_X$ 是個絕對連續機率分佈 (absolutely continuous probability distribution)，而 X 是個絕對連續隨機變數 (absolutely continuous random variable)。在這樣的情況下，我們可以使用定理 1.3.16 中的 Radon–Nikodym 定理，以建構一個非負可測函數 $p : \mathbb{R}^d \rightarrow \mathbb{R}_+$ 使得

$$\mathbb{P}_X(B) = \int_B p(x) \, dx.$$

除了在一測度為零的集合之上，此函數 p 的定義是唯一的，我們稱之為 X 的密度函數 (density function) 或機率密度函數 (probability density function)。此外，在一維的情況下 $d = 1$ ，對於所有 $\alpha \leq \beta$ ，我們有

$$\mathbb{P}(\alpha \leq X \leq \beta) = \int_{\alpha}^{\beta} p(x) \, dx.$$

註解 2.3.3： 若 $\mathbb{P}_X$ 對於任意 $\mathbb{R}^d$ 中的單點測度皆為零，則我們說 $\mathbb{P}_X$ 是個連續測度或連續分佈，且 X 是個連續隨機變數。我們不難驗證，絕對連續測度（或隨機變數）也會是連續的；但在習題 1.33 中我們看到，Cantor 分佈是個連續但不是絕對連續的（機率）測度。

第二小節 離散型隨機變數

第二章 機率論基礎

下面我們介紹在未來會常常使用的離散機率分佈。令 $(\Omega, \mathcal{P}(\Omega), \mathbb{P})$ 為離散機率空間，考慮值域空間 E 以及隨機變數 $X: \Omega \rightarrow E$ ，將對應到機率分佈 $\mathbb{P}_X$ 的質量函數記作 f_X ，根據不同的下列狀況我們會有不同的分佈。

均勻分佈 (Uniform distribution) 若 E 為有限集合， $n = |E|$ 為其元素個數，且質量函數 f_X 滿足以下條件：

$$f_X(x) = \mathbb{P}(X = x) = \frac{1}{n}, \quad \forall x \in E,$$

我們稱 X 為在 E 之上的均勻分佈，記作 $X \sim \text{Unif}(E)$ 。

例：投擲一顆六面的公正骰子，點數分別為 $\{1, \dots, 6\}$ 。

伯努力分佈 (Bernoulli distribution) 給定參數 $p \in [0, 1]$ ，若 $E = \{0, 1\}$ 且 f_X 滿足下列條件：

$$f_X(1) = \mathbb{P}(X = 1) = p, \quad f_X(0) = \mathbb{P}(X = 0) = 1 - p,$$

我們稱 X 為參數為 p 的伯努力分佈，記作 $X \sim \text{Ber}(p)$ 。

例：投擲一顆不公正硬幣，得到正面（記作 1）的機率為 p ，反面（記作 0）的機率為 $1 - p$ 。

二項式分佈 (Binomial distribution) 給定參數 $n \in \mathbb{N}_0$ 及 $p \in [0, 1]$ ，若 $E = \{0, \dots, n\}$ 且 f_X 滿足下列條件：

$$f_X(k) = \mathbb{P}(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}, \quad \forall k \in E,$$

我們稱 X 為參數為 (n, p) 的二項式分佈，記作 $X \sim \text{Bin}(n, p)$ 。

例：考慮上述不公正硬幣，投擲 n 次，則正面出現的次數滿足二項式分佈。



圖 2.2: 二項式分佈的質量函數，左圖的參數為 $n = 30, p = 0.2$ ，右圖的參數為 $n = 30, p = 0.5$ 。

幾何分佈 (Geometric distribution) 給定參數 $p \in (0, 1)$ ，若 $E = \mathbb{N}_0$ 且 f_X 滿足下列條件：

$$f_X(k) = \mathbb{P}(X = k) = (1 - p)^k p, \quad \forall k \in \mathbb{N}_0,$$

我們稱 X 為參數為 p 的幾何分佈，記作 $X \sim \text{Geo}(p)$ 。

例：投擲上述不公平硬幣，在得到第一次正面之前反面出現的次數，滿足幾何分佈。若我們把正面視為「成功」，反面視為「失敗」，則此分佈描述成功前必須要經過的失敗次數。




圖 2.3: 幾何分佈的質量函數，左圖的參數為 $n = 30, p = 0.2$ ，右圖的參數為 $n = 30, p = 0.4$ 。

超幾何分佈 (Hypergeometric distribution) 給定非負整數 N, K, n 滿足 $0 \leq K \leq N$ ，取 $E = \{(n - N + K) \vee 0, \dots, K \wedge n\}$ 且 f_X 滿足下列條件：

$$f_X(k) = \mathbb{P}(X = k) = \frac{\binom{K}{k} \binom{N - K}{n - k}}{\binom{N}{n}}, \quad \forall k \in E,$$

我們稱 X 為參數為 (N, K, n) 的超幾何分佈，記作 $X \sim \text{Hypergeo}(N, K, n)$ 。

例：在一個球箱中，有 N 顆球，其中 K 顆是白色的，當我們進行不重複抽樣取 n 顆球時，抽到的白球數量會滿足超幾何分佈 $\text{Hypergeo}(N, K, n)$ 。

帕松分佈 (Poisson distribution) 令 $\lambda > 0$ 為一參數， $E = \mathbb{N}_0$ 且 $\mathbb{P}$ 滿足下列條件：

$$\mathbb{P}(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad \forall k \in \mathbb{N}_0.$$

我們稱 X 為參數為 λ 的帕松分佈，記作 $X \sim \text{Pois}(\lambda)$ 。

第二章 機率論基礎



圖 2.4: 帕松分佈的質量函數，左圖的參數為 $\lambda = 5$ ，右圖的參數為 $\lambda = 10$ 。

註解 2.3.4：不管從理論或是應用的角度來看，帕松分佈都具有重要意義。在稍後的章節，當我們探討機率分佈的收斂時，我們可以證明帕松分佈可以被理解為二項式分佈的極限。換句話說，令 X_n 為滿足二項式分佈 $\text{Bin}(n, p_n)$ 的隨機變數，且當 n 趨近無窮大時，我們有 $np_n \rightarrow \lambda$ ，則

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = k), \quad \forall k \in \mathbb{Z}_{\geq 0}.$$

第三小節 有密度的隨機變數

在這個章節中，我們定義常見的連續隨機變數分佈，並且討論他們的性質。我們將所要討論的連續隨機變數記作 X ，並將他的機率密度函數記作 f_X 。

均勻分佈 (Uniform distribution) 令 $a < b$ ，若 p 可寫為

$$p(x) = \frac{1}{b-a} \mathbb{1}_{[a,b]}(x).$$

則稱 X 為在區間 $[a, b]$ 上的均勻分佈，記作 $X \sim \text{Unif}([a, b])$ 。

指數分佈 (Exponential distribution) 令 $\lambda > 0$ 為一額外參數，若 f_X 滿足：

$$f_X(x) = \lambda e^{-\lambda x} \mathbb{1}_{\mathbb{R}_{\geq 0}}(x), \quad \forall x \in \mathbb{R},$$

則稱 X 為參數為 λ 的指數分佈，記作 $X \sim \mathcal{E}(\lambda)$ 或 $X \sim \text{Exp}(\lambda)$ 。我們不難驗證，若 $X \sim \text{Exp}(\lambda)$ ，則

$$\mathbb{E}[X] = \frac{1}{\lambda} \quad \text{以及} \quad \text{Var}(X) = \frac{1}{\lambda^2}.$$




圖 2.5: 左邊是不同參數指數分佈的機率密度函數，右邊是他們的分佈函數。

常態分佈 (Normal distribution) 或高斯分佈 (Gaussian distribution) 令 $m \in \mathbb{R}$ 及 $\sigma > 0$ 為兩額外參數，若 f_X 滿足：

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right),$$

則稱 X 為均值為 m 變異數為 σ^2 的高斯分佈，記作 $X \sim \mathcal{N}(m, \sigma^2)$ 。我們不難驗證，若 $X \sim \mathcal{N}(m, \sigma^2)$ ，則

$$\mathbb{E}[X] = m \quad \text{以及} \quad \text{Var}(X) = \sigma^2.$$

當 $m = 0$ ，我們稱 X 置中 (centered)；當 $\sigma = 1$ ，我們稱 X 約化 (reduced)；當兩者皆成立，我們稱之為標準常態分佈 (standard normal distribution)。




圖 2.6: 左邊是不同高斯分佈的機率密度函數，右邊是他們的分佈函數，這裡我們取 $\mu = 0$ 。

柯西分佈 (Cauchy distribution) 給定參數 $\gamma > 0$ 及 $x_0 \in \mathbb{R}$ ，若 f_X 滿足：

$$f_X(x) = \frac{1}{\pi\gamma(1 + (\frac{x-x_0}{\gamma})^2)} = \frac{1}{\pi} \frac{\gamma}{(x-x_0)^2 + \gamma^2}, \quad \forall x \in \mathbb{R},$$

則稱 X 為參數為 (x_0, γ) 的柯西分佈，記作 $X \sim \text{Cauchy}(x_0, \gamma)$ 。我們可以檢查，柯西分佈的期望值是沒有定義的。（參照習題 2.15）




圖 2.7: 左邊是不同柯西分佈的機率密度函數，右邊是他們的分佈函數，這裡我們取 $x_0 = 0$ 。

伽瑪分佈 (Gamma distribution) 給定參數 $\alpha, \beta > 0$ ，若 f_X 滿足：

$$f_X(x) = \frac{1}{\Gamma(\alpha)} \beta^\alpha x^{\alpha-1} e^{-\beta x} \mathbb{1}_{x>0}, \quad \forall x \in \mathbb{R},$$

其中 $\Gamma(\alpha)$ 為伽瑪函數，定義做

$$\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-x} dx,$$

則我們稱 X 為參數為 (α, β) 的伽瑪分佈，記作 $X \sim \Gamma(\alpha, \beta)$ 或 $X \sim \text{Gamma}(\alpha, \beta)$ 。我們回顧伽瑪函數的重要性質：對於 $\alpha > 0$ ，我們有 $\Gamma(\alpha + 1) = \alpha \Gamma(\alpha)$ （變數變換）、 $\Gamma(1) = 1$ ，以及 $\Gamma(\frac{1}{2}) = \sqrt{\pi}$ 。




圖 2.8: 左邊是不同伽瑪分佈的機率密度函數，右邊是他們的分佈函數。

貝塔分佈 (Beta distribution) 給定參數 $\alpha, \beta > 0$ ，若 f_X 滿足：

$$f_X(x) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} \mathbb{1}_{x \in (0,1)}, \quad \forall x \in \mathbb{R},$$

其中 $B(\alpha, \beta)$ 為貝塔函數，定義做

$$B(\alpha, \beta) = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)},$$

則我們稱 X 為參數為 (α, β) 的貝塔分佈，記作 $X \sim \text{Beta}(\alpha, \beta)$ 。

註解 2.3.5：機率分佈 $\text{Beta}(1, 1)$ 為在 $[0, 1]$ 上的均勻分佈，且我們有下列對稱性：若 $X \sim \text{Beta}(\alpha, \beta)$ ，則 $1 - X \sim \text{Beta}(\beta, \alpha)$ 。




圖 2.9: 左邊是不同貝塔分佈的機率密度函數，右邊是他們的分佈函數。

第四節 隨機變數的動差

動差是隨機變數幕次的期望值，可以讓我們得到一些非線性的特性，例如在統計上有重要意義的變異數。在機率論中，動差方法 (method of moments) 有很多重要的應用，甚至可以拿來證明圖論、數論中各種存在性的問題，可以參見例如習題 2.24 和習題 2.25。

第一小節 動差及變異數

定義 2.4.1：固定正整數 $k \geq 1$ ，若實隨機變數 X 滿足 $\mathbb{E}[|X|^k] < \infty$ ，也就是說 $X \in L^k$ ，則我們說 X 的 k 階動差 (moment) 為有限。我們稱 $\mathbb{E}[X^k]$ 為 X 的 k 階動差。

定義 2.4.2：令 $X \in L^2(\Omega, \mathcal{P}(\Omega), \mathbb{P})$ ，則 X 的變異數 (variance) 定義為

$$\text{Var}(X) := \mathbb{E}[(X - \mathbb{E}[X])^2] \geq 0. \quad (2.4)$$

其標準差 (standard deviation) 則記作

$$\sigma_X = \sqrt{\text{Var}(X)}.$$

註解 2.4.3：我們可以這樣理解上述定義中的變異數 $\text{Var}(X)$ ：它是一種可以量測隨機變數 X 在其期望值 $\mathbb{E}[X]$ 附近分散程度的數學量。

在式 (2.4) 中，取平方是重要的，不然我們會有

$$\mathbb{E}[X - \mathbb{E}[X]] = \mathbb{E}[X] - \mathbb{E}[X] = 0,$$

而無法正確描述我們的隨機變數 X 到底離他的期望值多遠。

第二章 機率論基礎

若要避免相消為零的現象發生，我們可以考慮 $\mathbb{E}[|X - \mathbb{E}[X]|]$ ，他的好處是，我們不需要要求隨機變數 $X \in L^2$ ，我們只需要 $X \in L^1$ 的假設即足夠，但缺點是，絕對值的規律性比平方來得差，且在計算上比較不容易，因此才會考慮平方。在後面的章節中，我們也會看到取平方在機率理論中的重要性，這與中央極限定理有關係。

我們可以這樣理解上述定義中的變異數 $\text{Var}(X)$ ：它量測隨機變數 X 在其平均值 $\mathbb{E}[X]$ 附近分散的程度，另外我們可以注意到，若且為若 $\text{Var}(X) = 0$ 則 X 幾乎必然為常數。

命題 2.4.4： 變異數 $\text{Var}(X)$ 會滿足下列最佳化問題：

$$\text{Var}(X) = \inf_{a \in \mathbb{R}} \mathbb{E}[(X - a)^2].$$

證明：我們只需要證明，對於所有實數 a ，我們有

$$\mathbb{E}[(X - a)^2] = \text{Var}(X) + (\mathbb{E}[X] - a)^2.$$

透過直接的計算，我們有

$$\begin{aligned} \mathbb{E}[(X - a)^2] &= \mathbb{E}[(X - \mathbb{E}[X] + (\mathbb{E}[X] - a))^2] \\ &= \text{Var}(X) + 2(\mathbb{E}[X] - a)\mathbb{E}[X - \mathbb{E}[X]] + (\mathbb{E}[X] - a)^2 \\ &= \text{Var}(X) + (\mathbb{E}[X] - a)^2. \end{aligned}$$

□

我們能利用期望值及變異數估計隨機變數取值的機率：

馬可夫不等式 (Markov's inequality) 若 $X \in L_+^1(\Omega, \mathcal{A}, \mathbb{P})$ 且 $a > 0$ ，則

$$\mathbb{P}(X \geq a) \leq \frac{1}{a} \mathbb{E}[X].$$

柴比雪夫不等式 (Bienaymé-Chebyshev inequality) 若 $X \in L^2(\Omega, \mathcal{A}, \mathbb{P})$ 且 $a > 0$ ，則

$$\mathbb{P}(|X - \mathbb{E}[X]| \geq a) \leq \frac{1}{a^2} \text{Var}(X).$$

定義 2.4.5： 令 $X, Y \in L^2(\Omega, \mathcal{P}(\Omega), \mathbb{P})$ ，則它們的共變異數 (covariance) 定義為

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] = \mathbb{E}[X(Y - \mathbb{E}[Y])] = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y].$$

我們注意到，共變異數的定義是變異數的推廣： $\text{Var}(X) = \text{Cov}(X, X)$ 。

註解 2.4.6：兩隨機變數 X 及 Y 之間的共變異數測量它們之間的關聯性 (correlation)，這和隨機變數的獨立性是不一樣的。參閱第 3.1.2 小節。

註解 2.4.7：給定離散機率空間 $(\Omega, \mathcal{P}(\Omega), \mathbb{P})$ ，我們不難檢查共變異數函數

$$\text{Cov}(\cdot, \cdot) : L^2(\Omega, \mathcal{A}, \mathbb{P}) \times L^2(\Omega, \mathcal{A}, \mathbb{P}) \longrightarrow \mathbb{R}$$

是個對稱、雙線性的運算子。換句話說，對於所有 $X, Y, Z \in L^2(\Omega, \mathcal{A}, \mathbb{P})$ 及 $a, b \in \mathbb{R}$ ，我們有

$$\begin{aligned}\text{Cov}(X, Y) &= \text{Cov}(Y, X), \\ \text{Cov}(aX + bY, Z) &= a \text{Cov}(X, Z) + b \text{Cov}(Y, Z).\end{aligned}$$

這讓我們可以使用柯西不等式，進而得到

$$|\text{Cov}(X, Y)| \leq \sqrt{\text{Var}(X)} \sqrt{\text{Var}(Y)}.$$

此外，若 X 及 Y 其中之一幾乎必然為常數，則 $\text{Cov}(X, Y) = 0$ 。

定義 2.4.8：若 $X = (X_1, \dots, X_d)$ 為一值域為 $\mathbb{R}^d$ 的隨機變數，且假設其所有的分量都在 $L^2(\Omega, \mathcal{A}, \mathbb{P})$ 之中，則 X 的共變異數矩陣 (covariance matrix) 定義為

$$K_X = (\text{Cov}(X_i, X_j))_{1 \leq i, j \leq d}.$$

問題 2.4.9：試證明當 X 是個 d 維的實隨機變數時，其共變異數矩陣 K_X 是個半正定 (positive semi-definite) 對稱矩陣，換句話說，證明對於所有的 $\lambda = (\lambda_1, \dots, \lambda_d) \in \mathbb{R}^d$ ，我們有 $\lambda K_X \lambda^T \geq 0$ 。

問題 2.4.10：若 A 是個 $n \times d$ 維的矩陣，且 X 為 d 維實隨機變數，定義 $Y = AX$ ，試證明 $K_Y = AK_X A^T$ 。

第二小節 線性回歸

令 $X, Y_1, \dots, Y_n$ 為在 $L^2(\Omega, \mathcal{A}, \mathbb{P})$ 中的隨機變數，我們想要找出近似 X 而且能被寫為 $1, Y_1, \dots, Y_n$ 線性組合的隨機變數。換句話說，我們想要找出實數 $\beta_0, \dots, \beta_n$ 將下列數值最小化：

$$\mathbb{E}[(X - (\beta_0 + \beta_1 Y_1 + \dots + \beta_n Y_n))^2].$$

命題 2.4.11：當 (α_j) 為下列線性系統

$$\sum_{j=1}^n \alpha_j \text{Cov}(Y_j, Y_k) = \text{Cov}(X, Y_k), \quad 1 \leq k \leq n, \quad (2.5)$$

的任意一個解時，設

$$Z = \mathbb{E}[X] + \sum_{j=1}^n \alpha_j (Y_j - \mathbb{E}[Y_j]), \quad (2.6)$$

則我們有

$$\inf_{\beta_0, \dots, \beta_n \in \mathbb{R}} \mathbb{E} \left[(X - (\beta_0 + \beta_1 Y_1 + \dots + \beta_n Y_n))^2 \right] = \mathbb{E}[(X - Z)^2].$$

證明：令 H 為由 $1, Y_1, \dots, Y_n$ 生成在 $L^2(\Omega, \mathcal{A}, \mathbb{P})$ 中的子向量空間，由於 Z 會讓泛函函數 $U \in H \mapsto \|X - U\|_2$ 達到最小值，所以 Z 是 X 在 H 之上的正交投影。若我們把 Z 寫作

$$Z = \alpha_0 + \sum_{j=1}^n \alpha_j (Y_j - \mathbb{E}[Y_j]), \quad (2.7)$$

透過正交投影的性質，我們有 $\mathbb{E}[(X - Z) \cdot 1] = 0$ ，也就是說 $\alpha_0 = \mathbb{E}[X]$ 。同樣的，對於所有 $1 \leq k \leq n$ ，我們有

$$\mathbb{E}[(X - Z) \cdot (Y_k - \mathbb{E}[Y_k])] = 0,$$

也就是說 $\text{Cov}(X, Y_k) = \text{Cov}(Z, Y_k)$ ；接著利用式 (2.7) 中 Z 的線性組合，我們可以得到式 (2.5)。

反過來說，若 (α_i) 滿足式 (2.5)，則式 (2.6) 中定義的 Z 是個在 H 中的元素，而且 $X - Z$ 和 H 是正交的，也就是說 Z 是 X 在 H 上的正交投影。□

第三小節 特徵函數

定義 2.4.12：若 X 是個值域為 $\mathbb{R}^d$ 的隨機變數，則其特徵函數 (characteristic function) $\Phi_X : \mathbb{R}^d \rightarrow \mathbb{C}$ 定義為

$$\Phi_X(\xi) = \mathbb{E}[\exp(i\xi \cdot X)], \quad \xi \in \mathbb{R}^d.$$

註解 2.4.13：上述定義也可以重新寫作

$$\Phi_X(\xi) = \int_{\mathbb{R}^d} e^{i\xi \cdot x} \mathbb{P}_X(dx).$$

換句話說，我們可以把 Φ_X 視作 $\mathbb{P}_X$ 的傅立葉變換 (Fourier transform)： $\Phi_X(\xi) = \hat{\mathbb{P}}_X(\xi)$ 。另外，從勒貝格控制收斂定理可以得知 Φ_X 為一在 $\mathbb{R}^d$ 上的連續有界函數。

我們這裡列出以第 2.3 節中提到的機率分佈為例子，所對應到的特徵函數。

隨機變數 X	特徵函數 $\Phi_X(\xi)$
$\text{Ber}(p)$	$1 - p + pe^{i\xi}$
$\text{Bin}(n, p)$	$(1 - p + pe^{i\xi})^n$
$\text{Geo}(p)$	$\frac{p}{1 - (1 - p)e^t}$
$\text{Pois}(\lambda)$	$\exp(\lambda(e^{i\xi} - 1))$
$\text{Unif}([a, b])$	$\frac{e^{i\xi b} - e^{i\xi a}}{i\xi(b - a)}$
$\mathcal{E}(\lambda)$	$\frac{\lambda}{\lambda - i\xi}$
$\mathcal{N}(m, \sigma^2)$	$\exp(im\xi - \frac{1}{2}\sigma^2\xi^2)$

在這小節，我們將會證明特徵函數可以完全決定隨機變數的機率分佈。

首先，我們證明常態分佈在傅立葉變換 $\mathcal{F} : \mathbb{P}_X \mapsto \hat{\mathbb{P}}_X$ 之下的不變性 (invariance)。

引理 2.4.14：若 X 為一分佈為 $\mathcal{N}(0, \sigma^2)$ 的隨機變數，則

$$\Phi_X(\xi) = \exp\left(-\frac{\sigma^2\xi^2}{2}\right), \quad \xi \in \mathbb{R}.$$

證明：透過被積分式的奇偶性，我們可以得到 $\Phi_X(\xi)$ 的虛數部份為零，所以我們要計算

$$f(\xi) = \int_{\mathbb{R}} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \cos(\xi x) dx.$$

我們對上述式子微分，由於可積函數 $x \mapsto |x|e^{-x^2/2}$ 是 $x \mapsto x \sin(\xi x)e^{-x^2/2}$ 的上界，所以微分算子可以移至積分之內，也就是說

$$f'(\xi) = - \int_{\mathbb{R}} \frac{1}{\sqrt{2\pi}} x e^{-x^2/2} \sin(\xi x) dx.$$

我們對上述式子進行部份積分，可以得到

$$f'(\xi) = -\xi \int_{\mathbb{R}} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \cos(\xi x) dx = -\xi f(\xi).$$

因此我們證明出來 f 是微分方程 $f'(\xi) = -\xi f(\xi)$ 且初始值為 $f(0) = 1$ 的解，由於唯一性，我們得到 $f(\xi) = \exp(-\xi^2/2)$ 。□

定理 2.4.15：任一隨機變數 X 的特徵函數可以完全定義其分佈，換句話說，傅立葉變換 $\mathcal{F} : \mathbb{P}_X \mapsto \hat{\mathbb{P}}_X$ 在 $\mathbb{R}^d$ 之上的分佈所構成的空間是單射 (injective) 的。

證明：首先，假設一維的情況 $d = 1$ 。對於所有的 $\sigma > 0$ ，我們可以定義常態分佈 $\mathcal{N}(0, \sigma^2)$ 的密度函數

$$g_\sigma(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x^2}{2\sigma^2}\right).$$

若 μ 為一在 $\mathbb{R}$ 之上的機率測度，我們定義：

$$\begin{aligned} f_\sigma(x) &= \int_{\mathbb{R}} g_\sigma(x-y) \mu(dy) \stackrel{(\text{def})}{=} g_\sigma * \mu(x), \\ \mu_\sigma(dx) &= f_\sigma(x) dx. \end{aligned}$$

要證明此定理，我們將分兩步驟：

- (1) μ_σ 可以完全被 $\hat{\mu}$ 所定義；
- (2) 對於任何的函數 $\varphi \in C_b(\mathbb{R})$ ，當 $\sigma \rightarrow 0$ 我們有下列收斂 $\int \varphi(x) \mu_\sigma(dx) \rightarrow \int \varphi(x) \mu(dx)$ 。

首先，我們來證明第一點。透過引理 2.4.14，我們可以得到，對於所有的 $x \in \mathbb{R}$ ，有

$$\sqrt{2\pi\sigma^2} g_\sigma(x) = \exp\left(-\frac{x^2}{2\sigma^2}\right) = \int_{\mathbb{R}} e^{i\xi \cdot x} g_{1/\sigma}(\xi) d\xi.$$

接著，我們可以把 $f_\sigma(x)$ 重新寫作

$$\begin{aligned} f_\sigma(x) &= \int_{\mathbb{R}} g_\sigma(x-y) \mu(dy) = \frac{1}{\sqrt{2\pi\sigma^2}} \int_{\mathbb{R}} \left(\int_{\mathbb{R}} e^{i\xi(x-y)} g_{1/\sigma}(\xi) d\xi \right) \mu(dy) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \int_{\mathbb{R}} e^{i\xi x} g_{1/\sigma}(\xi) \left(\int_{\mathbb{R}} e^{-i\xi y} \mu(dy) \right) d\xi \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \int_{\mathbb{R}} e^{i\xi x} g_{1/\sigma}(\xi) \hat{\mu}(-\xi) d\xi. \end{aligned} \tag{2.8}$$

在上式的倒數第二個等式當中，我們用富比尼定理（定理 1.4.3），因為 μ 是個機率測度且 $g_{1/\sigma}$ 對勒貝格測度來說，是個可積函數。

接著證明第二點，首先注意到，對於所有的 $\varphi \in C_b(\mathbb{R})$ ，我們有

$$\int \varphi(x) \mu_\sigma(dx) = \int \varphi(x) \left(\int g_\sigma(y-x) \mu(dy) \right) dx = \int g_\sigma * \varphi(y) \mu(dy), \tag{2.9}$$

其中我們用到富比尼定理以及 g_σ 是個偶函數的特性。接著，我們使用 g_σ 的其他特性：

$$\int g_\sigma(x) dx = 1, \quad \text{以及} \quad \lim_{\sigma \rightarrow 0} \int_{\{|x| > \varepsilon\}} g_\sigma(x) dx = 0, \quad \forall \varepsilon > 0,$$

這讓我們簡單得到

$$\forall y \in \mathbb{R}, \quad \lim_{\sigma \rightarrow 0} g_\sigma * \varphi(y) = \varphi(y). \tag{2.10}$$

由於對於所有的 $\sigma > 0$ ， $|g_\sigma * \varphi| \leq \sup |\varphi|$ ，透過勒貝格收斂定理，我們有

$$\lim_{\sigma \rightarrow 0} \int \varphi(x) \mu_\sigma(dx) = \lim_{\sigma \rightarrow 0} \int g_\sigma * \varphi(y) \mu(dy) = \int \varphi(x) \mu(dx).$$

因此此定理在一維的情況下為真。

在 d 維的情況下，證明相似。我們定義下列函數

$$g_\sigma^{(d)}(x_1, \dots, x_d) = \prod_{j=1}^d g_\sigma(x_j),$$

並且利用對於所有 $\xi \in \mathbb{R}^d$ ，我們有

$$\int_{\mathbb{R}^d} g_\sigma^{(d)}(x) e^{i\xi \cdot x} dx = \prod_{j=1}^d \int_{\mathbb{R}} g_\sigma(x_j) e^{i\xi_j x_j} dx_j = (2\pi\sigma^2)^{d/2} g_{1/\sigma}^{(d)}(\xi).$$

□

問題 2.4.16：將 $C_b(\mathbb{R})$ 中緊緻支撐 (compactly supported) 函數構成的集合記作 $C_c(\mathbb{R})$ 。證明若 $\varphi \in C_c(\mathbb{R})$ ，則可以強化式 (2.10) 中的收斂為在 $\mathbb{R}$ 上的均勻收斂；換句話說，證明

$$\forall \varphi \in C_c(\mathbb{R}), \quad \|g_\sigma * \varphi - \varphi\|_\infty \xrightarrow{\sigma \rightarrow 0} 0.$$

命題 2.4.17：令 $X = (X_1, \dots, X_n)$ 為一 n 維的實隨機變數，假設 $\|X\|_2^2$ 是個可積的隨機變數，則 Φ_X 是個 C^2 函數，而且當 $\xi = (\xi_1, \dots, \xi_n)$ 趨近於 0 時，我們有

$$\Phi_X(\xi) = 1 + i \sum_{j=1}^d \xi_j \mathbb{E}[X_j] - \frac{1}{2} \sum_{j,k=1}^d \xi_j \xi_k \mathbb{E}[X_j X_k] + o(\|\xi\|^2).$$

證明：下面三個性質並不難檢查：

- (a) 對於所有 $\xi \in \mathbb{R}^n$ ，函數 $x \mapsto e^{i\xi \cdot x}$ 對於 $\mathbb{P}_X$ 是可積的。
- (b) 對於所有 $x \in \mathbb{R}^n$ ，函數 $\xi \mapsto e^{i\xi \cdot x}$ 對於 ξ 是可微的，而且他在 ξ 的微分寫做：

$$\eta = (\eta_1, \dots, \eta_n) \mapsto \sum_{i=1}^n i \eta_i x_i e^{i\xi \cdot x} \quad \text{或} \quad \sum_{j=1}^n i x_j e^{i\xi \cdot x} d\xi_j.$$

- (c) 對於所有 $j = 1, \dots, n$ ，偏微分 $x \mapsto i x_j e^{i\xi \cdot x}$ 是連續的，而且可以被 x_j 所控制住，由於 $X_j \in L^2 \subseteq L^1$ ，這個控制函數對 $\mathbb{P}_X$ 是可積的。

因此，定理 1.2.24 讓我們可以交換微分算子和積分算子的順序，讓我們改寫 Φ_X 的微分，也就是說：

$$\forall j = 1, \dots, n, \quad \frac{\partial \Phi_X}{\partial \xi_j}(\xi) = i \mathbb{E}[X_j e^{i\xi \cdot X}].$$

此外，定理 1.2.22 告訴我們這些偏微分都是連續的。

對於二階微分，我們可以使用相似的方法。更確切來說，我們會需要用到 $\mathbb{E}[|X_j X_k|] \leq \mathbb{E}[X_j]^2 \mathbb{E}[X_k]^2 < \infty$ 來解釋二階微分和積分可以交換。□

要小心的是，不同於特徵函數可以完全描述機率分佈，在一般情況下，只知道動差 $(\mathbb{E}[X^k])_{k \geq 0}$ 並不足以描述 X 的機率分佈。在習題 2.22 中，我們會看到反例，也就是說，我們會構造出（至少）兩個不同的機率分佈，使得他們的所有動差皆是相等的。接著在習題 2.23 中，我們會討論在什麼樣的情況之下，動差可以唯一決定機率分佈。

第四小節 生成函數

當離散隨機變數的值域為非負整數 $\mathbb{N}_0$ 時，我們可以定義他的生成函數 (generating function)。

定義 2.4.18：令 X 為一值域為 $\mathbb{N}_0$ 的隨機變數，其生成函數 G_X 定義在下列級數會收斂的 $s \in \mathbb{C}$ 上：

$$G_X(s) = \mathbb{E}[s^X] = \sum_{n=0}^{\infty} \mathbb{P}(X = n) s^n. \quad (2.11)$$

反過來說，若我們知道離散隨機變數 X 的生成函數，透過讀取他的係數，我們也可以描述 X 的分佈。

由式 (2.11) 定義出來的級數會滿足一些基本性質，這部份屬於微積分的先備知識，這裡只做回顧。

收斂性 存在收斂半徑 (radius of convergence) $0 \leq R \leq \infty$ 使得當 $|s| < R$ 時，級數 $G_X(s)$ 會收斂；當 $|s| > R$ 時，級數 $G_X(s)$ 會發散。此外，對於所有 $R' < R$ ，級數 $G_X(s)$ 在 $\{s : |s| \leq R'\}$ 上會均勻收斂。這裡我們注意到，由於 $G_X(1) = 1$ ，所以顯然有 $R \geq 1$ 。

微分性 在定義域 $\{s : |s| < R\}$ 上，我們可以一項一項對級數 $G_X(s)$ 微分或積分無限多次。

唯一性 若存在 $0 < R' \leq R$ 使得當 $|s| < R'$ 時，等式 $G_X(s) = G_Y(s)$ 成立，則對於所有 $n \in \mathbb{N}_0$ ，我們有 $\mathbb{P}(X = n) = \mathbb{P}(Y = n)$ 。此外，我們有

$$\mathbb{P}(X = n) = \frac{1}{n!} G_X^{(n)}(0), \quad \forall n \geq 0.$$

連續性 【Abel 定理】由於各項 $\mathbb{P}(X = n)$ 皆為非負，若 $R < \infty$ ，我們有

$$\lim_{s \uparrow R} G_X(s) = \sum_{n=0}^{\infty} \mathbb{P}(X = n) R^n.$$

命題 2.4.19：我們可以透過 G_X 的微分來計算 X 的期望值：

$$G'_X(1) := \lim_{s \uparrow 1} G_X(s) = \mathbb{E}[X] \in [0, \infty].$$

更一般來說，對於所有正整數 $p \geq 1$ ，我們有

$$G_X^{(p)} := \lim_{s \uparrow 1} G_X^{(p)}(s) = \mathbb{E}[X(X-1)\dots(X-p+1)],$$

也就是說透過 X 的生成函數，我們可以簡單計算 X 的所有動差。此外，對於 $X \in L^2(\Omega, \mathcal{P}(\Omega), \mathbb{P})$ ，我們還有

$$\text{Var}(X) = G''_X(1) + G'_X(1) - G'_X(1)^2.$$

證明：對於所有正整數 $p \geq 1$ ，根據 $G_X^{(p)}(s)$ 在 $\{s : |s| < R\}$ 上的連續性（已知 $R \geq 1$ ），我們有

$$\lim_{s \uparrow 1} G_X^{(p)}(s) = \sum_{n=0}^{\infty} \mathbb{P}(X=n) \cdot n(n-1)\dots(n-p+1) = \sum_{n=0}^{\infty} \mathbb{P}(X=n) \cdot \varphi(n),$$

其中 $\varphi(n) = n(n-1)\dots(n-p+1)$ ，得證。

令 $X \in L^2(\Omega, \mathcal{P}(\Omega), \mathbb{P})$ ，我們根據前面性質，可以得到

$$\mathbb{E}[X^2] = \mathbb{E}[X(X-1)] + \mathbb{E}[X] = G''_X(1) + G'_X(1),$$

因此 $\text{Var}(X) = \mathbb{E}[X^2] - \mathbb{E}[X]^2 = G''_X(1) + G'_X(1) - G'_X(1)^2$ ，得證。 □

範例 2.4.20：若 X 是滿足二項式分佈 $\text{Bin}(n, p)$ 的隨機變數，則他的生成函數寫作：

$$G_X(s) = \sum_{k=0}^n \binom{n}{k} p^k (1-p)^{n-k} s^k = ((1-p) + ps)^n.$$

我們可以計算他的期望值

$$\mathbb{E}[X] = G'_X(s)_{s=1} = [n((1-p) + ps)^{n-1}p]_{s=1} = np.$$

若要計算他的變異數，我們先計算

$$G''_X(1) = [n(n-1)((1-p) + ps)^{n-2}p^2]_{s=1} = n(n-1)p^2,$$

接著帶入

$$\text{Var}(X) = n(n-1)p^2 + np - (np)^2 = np - np^2 = np(1-p).$$

第二章 機率論基礎

當我們的目的是要計算 X 的動差時，我們可以直接定義他的動差生成函數 (moment generating function)，這可以簡化我們的計算。

定義 2.4.21：給定取值在 $\mathbb{N}_0$ 中的離散隨機變數 X ，我們定義他的動差生成函數 (moment generating function)，也稱作指數生成函數 (exponential generating function) 為

$$M_X(t) := G_X(e^t) = \mathbb{E}[e^{tX}],$$

其中我們將 G_X 的收斂半徑記作 R ，並要求 $e^t < R$ 。

註解 2.4.22：若我們以 $M_X(t) := \mathbb{E}[e^{tX}]$ 來定義動差生成函數，則我們只需要要求 X 為實數離散隨機變數即可。

命題 2.4.23：離散隨機變數 X 的動差可以透過 M_X 的微分來計算。更確切的說，對於所有非負整數 $k \geq 0$ ，我們有

$$\mathbb{E}[X^k] = M_X^{(k)}(0).$$

證明：我們有

$$\begin{aligned} M_X(t) &= \sum_{k=0}^{\infty} e^{tk} \mathbb{P}(X = k) = \sum_{k=0}^{\infty} \sum_{n=0}^{\infty} \frac{(tk)^n}{n!} \mathbb{P}(X = k) \\ &= \sum_{n=0}^{\infty} \frac{t^n}{n!} \left(\sum_{k=0}^{\infty} k^n \mathbb{P}(X = k) \right) = \sum_{n=0}^{\infty} \frac{t^n}{n!} \mathbb{E}[X^n]. \end{aligned}$$

□

我們也能夠對 X 做拉普拉斯轉換 (Laplace transform)：

$$L_X(\lambda) := \mathbb{E}[e^{-\lambda X}].$$

要注意的是，與指數生成函數相同，這並不是對於所有 $\lambda \in \mathbb{R}$ 都是有定義的。

第五小節 尾端機率

給定隨機變數 X ， $\mathbb{P}(|X| > \lambda)$ 或 $\mathbb{P}(X > \lambda)$ 稱作尾端機率 (tail probability)。一般來講，若我們能夠有效控制 X 越高階的動差，則代表尾端機率會越小，且反之亦然。

定義 2.4.24：根據尾端機率，我們可以將隨機變數分佈歸類為：

(1) 次高斯分佈 (sub-Gaussian distribution) : 存在 $C, c > 0$ 使得

$$\mathbb{P}(|X| > x) \leq C \exp(-cx^2), \quad x \rightarrow \infty.$$

(2) 重尾分佈 (heavy-tailed distribution) : 存在 $C, \alpha > 0$ 使得

$$\mathbb{P}(|X| > x) \sim Cx^{-\alpha}, \quad x \rightarrow \infty.$$

註解 2.4.25 : 我們可以注意到，柯西分佈會是個重尾分佈，因為如果 $X \sim \text{Cauchy}(0, 1)$ ，則

$$\mathbb{P}(|X| > x) \sim \frac{2}{\pi x}, \quad x \rightarrow \infty.$$

此外，高斯分佈也是個次高斯分佈。

問題 2.4.26 : 給定隨機變數 X ，則下列三敘述等價：

- (1) X 是個次高斯分佈；
- (2) 存在 $C, c > 0$ 使得對於所有 $t \in \mathbb{R}$ ，我們有 $\mathbb{E}[e^{tX}] \leq C \exp(ct^2)$ ；
- (3) 存在 $C > 0$ 使得對於所有 $k \geq 1$ ，我們有 $\mathbb{E}[|X|^k] \leq (Ck)^{k/2}$ 。

問題 2.4.27 : 令 X 為實隨機變數且 $k > 0$ 。若 X 在 L^k 中，證明當 $\lambda \rightarrow \infty$ 時，我們有

$$\lambda^k \mathbb{P}(|X| > \lambda) \rightarrow 0.$$