

隨機變數

黃文璋

國立高雄大學應用數學系

1 隨機變數

假設有一機率空間 $(\Omega, \mathcal{F}, \mathcal{P})$ 。此機率空間可能是觀測某一隨機現象而得，或就是給定而不論其由來。

樣本空間中的元素，不一定是數字，可以是紅球及白球，也可能是正面及反面等。做民意調查，想了解民眾對某議題的看法，選項可能有極力贊成、贊成、不贊成、極不贊成，及沒意見等。我們一向比較喜歡處理數字的問題。對上述情況，可將紅球視為1，白球視為0；正面視為1，反面視為0；極力贊成視為5，贊成視為4，不贊成視為3，極不贊成視為2，沒意見視為1。也就是將實驗的結果數量化。

調查選民對某候選人支持與否，以1表支持，0表不支持。雖是數量化了，但若調查1,000位選民，則樣本空間中共有 $2^{1,000}$ 個元素，每一元素為一串長達1,000個的0或1的數字，其中第*i*個數字為1，表第*i*個選民支持該候選人，0表不支持。這麼大的樣本空間不但難以掌握，也顯得累贅。因我們可能只對其中共有多少人支持該候選人感到興趣。而究竟是那幾個選民支持，此訊息並不重要。因此可令

$$X = 1,000 \text{ 個數字中 } 1 \text{ 的個數}.$$

則對 X , 樣本空間成為 $\{0, 1, 2, \dots, 1,000\}$, 減小許多。

即使原先樣本空間中的元素就已是數字, 因種種目的, 我們仍可能會考慮它的某一函數。例如, 若隨機選取一蘋果, 量測其重量, 則可取樣本空間 $\Omega = (0, \infty)$ 。若蘋果每單位重量的價格為 a 元, 則將蘋果的重量 ω , 對應至 $X = a\omega$, 而得其價格。當然我們也可以一開始就是觀測一隨機選取的蘋果之價格, 由於 $a > 0$, 此時樣本空間仍可取為 $(0, \infty)$ 。

由於以上這些原因, 隨機變數(random variable)的概念便自然地產生了。所謂隨機變數, 就是一個定義在樣本空間 Ω 的實函數。若以 X 表一隨機變數, 則此函數的定義域為 Ω , 對應域為實數集合 R , 值域則為 R 的一個子集合。換句話說對 $\forall \omega \in \Omega$, $X(\omega) \in R$ 。

即使不論上述所提的那些原因, 在數學裡我們本來就經常在考慮各種函數。有些應用性的問題, 常可化為解跟某一函數有關的問題。函數在數學中的角色太重要, 數學中常在討論函數的各種性質。這樣看來, 隨機變數的產生, 就更不奇怪了。在同一樣本空間, 往往可定義出無限多個隨機變數。定義隨機變數, 可能是因實際需要, 也可能只是純粹數學的目的。

其實在很多隨機試驗裡, 我們早就隱含地使用隨機變數了。例如, 投擲一骰子2次, 令 X 表點數和; 投擲一銅板20次, 令 Y 表所得正面數等。

對於隨機變數 X , 可以想成原先觀測到 ω , 再轉換至 $X(\omega)$, 樣本空間由 Ω 轉為 R (或 R 的一個子集合)。但也可想成所觀測到的結果就是 X 。如前述隨機選取蘋果的例子。又如, 前述民調的例子, 負責抽樣的人有原始資料, 但他整理好後, 交出來的統計資料, 是支持的人數 X 。對大部分的人而言, 觀察值就是 X , 樣本空間為 $\{0, 1, \dots, 1,000\}$ 。由此可見隨機變數亦可是一觀測值, 視為一隨機試驗的結果, 即視為樣本。

隨機變數的概念既然是如此卑之無甚高論, 它不過就是一個函數(或僅是不同階段下的樣本), 但我們也經常聽到有人說他是在進了(統計)博士班之後, 才終於了解隨機變數的意義。這又是為什麼呢?

首先以往我們對函數, 常以 f, g, h 或大寫的 F, G, H 等命名, 參數(或稱變數), 則以 x, y, z 等表示。有時我們說有一函數 $f(x)$, 即使因函數較多, 有時會取名為 $a(x), b(x)$ 等, 或藉助希臘字母 $\xi(x), \eta(x)$ 等, 較少見到

以大寫的英文字母 X, Y, Z 當做函數。但對於隨機變數，我們往往以大寫的 X, Y, Z 等命名。又以往的函數，變數常是附在一起的，如 $f(x), g(y)$ 等。但隨機變數這種函數，其變數並不常與函數一起出現。例如，我們會寫 $f(x) = 3, g(y) = 5$ 等。但對隨機變數，往往寫成 $X = 3, Y^2 = 7$ 等。尤有進者，除了在一開始定義時，說隨機變數為一實函數，之後我們很少稱它為函數，連名稱都含有“變數”。因此不易使人與以往所學的函數連結在一起。

再看一個原因。隨機變數定義於樣本空間，樣本空間中的元素之出現情況是隨機的，以一機率函數來描述。例如，在數學裡解方程式是很平常的。我們說解 $f(x) = 3$ ，就是找出滿足 $f(x) = 3$ 的實數 x 。但對隨機變數 X ，我們較少說解 $X = 3$ 。 X 如果是由某一 Ω 映至實數 R ，是可以有一滿足 $X(\omega) = 3$ 之解集合 $\{\omega | X(\omega) = 3\}$ (如同方程式可能不易解，有時無法明確地表示出此集合)。但我們通常不會就此打住，而會去求此集合之機率。甚至後來經過一番改造(下一節會說明)，我們常略去解 $X = 3$ 的過程，而直接給出 $X = 3$ 的機率(見底下例2)。換句話說，雖然本身是一函數，但常另有跟機率有關的函數，伴隨一隨機變數，指揮該隨機變數的行為。那些函數的味道，就比較接近我們以往所遇到的函數。而那些函數也採用一般我們熟悉的函數之符號，如 f, g, h 及 F, G, H 等。這也可以解釋為什麼在隨機變數這一階段，我們不採慣用的函數符號。

第三個原因是，由於在樣本空間 Ω 上， σ -體 \mathcal{F} 選取的不同，使得並非每一由 Ω 映至 R 的函數，皆可當做隨機變數。一般要求(尤其在較高等的機率論中)還要滿足

$$(1) \quad \text{對 } \forall x \in R, \{\omega | X(\omega) \leq x\} \in \mathcal{F}.$$

為什麼要滿足此條件，也留在下一節再說明。如果 \mathcal{F} 取得小些，則有些 Ω 上的實函數，就不一定滿足條件(1)，因此就非隨機變數了。數學家一向愛好此道，給一定義，列出一些條件，總會讓它有時滿足，有時不滿足，問題因此變化多端。雖然增加挑戰性，對初學者而言，迷惘也隨之而生。幸好在統計學裡， \mathcal{F} 常取得夠大。例如，若 Ω 為一可數的集合，我們通常取 \mathcal{F} 為包

含 Ω 之所有子集合所形成的集合，因此條件(1)自然成立。如此一來所有由 Ω 映至 R 的函數，便皆為隨機變數了。

其他還有若干初學者不易了解隨機變數的概念之原因，我們陸續會解釋。

隨機變數常以大寫的英文字母表示，而它的觀測值則以對應的小寫字母表示。有時會說“隨機變數 X 取值 x ”，或說“求 $X = x$ 之機率”。

定義一隨機變數後，其值域可視為新的樣本空間，那原來的機率函數(定義在原來樣本空間所產生之 σ -體)，是否仍適用此隨機變數？

假設樣本空間 $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ ，且如一般，取 \mathcal{F} 為包含 Ω 之所有子集合所形成的 σ -體。定義一隨機變數 X ，其值域以 $\Omega_1 = \{x_1, x_2, \dots, x_m\}$ ， $m \leq n$ ，表之。觀測到 $X = x_i$ ，若且唯若原試驗的結果為 $\omega \in \Omega$ ，且使得 $X(\omega) = x_i$ 。則可取 Ω_1 為新的樣本空間， Ω_1 之所有子集合所形成的 σ -體以 \mathcal{F}_1 表之，而新的機率函數為 P_X ，其中

$$(2) \quad P_X(X = x_i) = P(\{\omega | \omega \in \Omega \text{ 且 } X(\omega) = x_i\}),$$

如此便得一新的機率空間 $(\Omega_1, \mathcal{F}_1, P_X)$ 。要注意的是，比較好的寫法是 $P_X(\{X = x_i\})$ ，因 $\{X = x_i\}$ 才是一集合，不過為了簡便，我們常簡單地寫成 $P_X(X = x_i)$ ，有時寫成 $P_X\{X = x_i\}$ 。可以驗證 P_X 的確滿足機率函數的公理。雖然 P_X 與 P 為不同的函數(定義域便不同了)，但因有(2)式，今後如果不會混淆，我們通常只寫 $P(X = x_i)$ ，且將 P 解釋為“機率”的意思。

例1. 投擲一銅板3次，並觀測3次所得結果。則樣本空間 $\Omega = \{\text{正正正, 正正反, 正反正, 反正正, 正反反, 反反正, 反反反}\}$ ，其中“正正反”表頭兩次出現正面，第三次出現反面，餘類推。且設每一樣本之機率為 $1/8$ (因此這是一公正的銅板)。令 X 表共得之正面數。顯然 X 之值域為 $\{0, 1, 2, 3\}$ 。則

$$P(X = 1) = P(\{\text{正反反, 反正反, 反反正}\}) = \frac{3}{8}.$$

同理可得 $P(X = 0) = 1/8$, $P(X = 2) = 3/8$, $P(X = 3) = 1/8$ 。

次令 $Y = \text{正面數} - \text{反面數}$ 。則 Y 之值域為 $\{-3, -1, 1, 3\}$, 且

$$P(Y = -3) = P(\{\text{反反反}\}) = \frac{1}{8}。$$

同理可得 $P(Y = -1) = P(Y = 1) = 3/8$, $P(Y = 3) = 1/8$ 。

例2. 投擲一公正的銅板 100 次, 並觀測 100 次所得結果。則樣本空間 Ω 中共有 2^{100} 個元素。由於此銅板為公正, 所以每個樣本之機率均相同, 皆為 $1/2^{100}$ 。令 X 表所得之正面數。欲求 $X = 10$ 之機率。因每一樣本皆為一串長達 100 的“正、反”文字, 本例不像上例可輕易列舉出對應 $X = 10$ 之原事件。但利用排列組合的技巧, 可得

$$P(X = 10) = \frac{\Omega \text{中有 } 10 \text{ 個“正”之元素個數}}{\Omega \text{之元素個數}} = \frac{\binom{100}{10}}{2^{100}}。$$

又對 $i = 0, 1, \dots, 100$,

$$P(X = i) = \frac{\binom{100}{i}}{2^{100}}。$$

雖然我們並未展示出事件 $\{X = i\}$ 究竟為何, 但其機率卻可求出。

一般而言, 令 Ω_1 表隨機變數 X 所引發出來的樣本空間, 則對 $\forall A \subset \Omega_1$, 我們定義引發出來的機率函數

$$P(X \in A) = P(\{\omega | \omega \in \Omega, \text{ 且 } X(\omega) \in A\})。$$

例3. 如果 Ω 本來就是實數的一個子集合, 則 $X(\omega) = \omega$ 為一很自然的隨機變數。例如, 一袋中有 10 張紙牌, 分別寫數字 1 至 10。隨機地取一張, 觀測所得之點數。則樣本空間 $\Omega = \{1, 2, \dots, 10\}$ 。令 $X(\omega) = \omega$, 便得一隨機變數。另一種講法是自袋中隨機取一張紙牌, 並令 X 表所得之點數。這種講法就是直接引進隨機變數。

其他如令 Y 表某袋中的紅球數, 令 Z 表某校戴眼鏡的學生人數, 都是直接引進隨機變數之例。紅球、戴眼鏡本來皆非數字, 但因我們將觀測的結

累數量化，或者說考慮數值上的特性，便產生了隨機變數。

在同一樣本空間中，可定義無數個隨機變數。即使 $\Omega = \{0, 1\}$ 只有兩個元素，對任二實數 a, b ，令 $X(0) = a, X(1) = b$ ，便得一隨機變數。

常數也是一隨機變數。即對一實數 c ，若 $X(\omega) = c, \forall \omega \in R$ ，則 X 為一隨機變數。有時以 $X \equiv c$ 表之。這種只取一個值之隨機變數，由於並不會變，雖然仍視為隨機變數，但稱之為退化的(degenerate)隨機變數。

例4. 對例1中的 Ω ，依序令 $Z(\text{正正正}) = a_1, Z(\text{正正反}) = a_2, \dots, Z(\text{反反反}) = a_8$ ，其中 a_1, a_2, \dots, a_8 皆為實數，則 Z 為一隨機變數。可看出若取 $a_1 = 3, a_2 = a_3 = a_4 = 2, a_5 = a_6 = a_7 = 1, a_8 = 0$ ，即得例1中之 X ；若取 $a_1 = 3, a_2 = a_3 = a_4 = 1, a_5 = a_6 = a_7 = -1, a_8 = -3$ ，即得例1中的 Y 。任一定義於 Ω 上的隨機變數，皆可經由適當地選取 a_1, \dots, a_8 而得。

再給一特殊但常見之隨機變數。

例5. 設 A 為樣本空間 Ω 之一子集合。令 I_A 表 A 之指示函數(indicator function)，即若 A 發生，則 $I_A = 1$ ，否則 $I_A = 0$ 。 I_A 便是“指示”事件 A 是否發生。因此

$$I_A(\omega) = \begin{cases} 1, & \omega \in A, \\ 0, & \omega \notin A. \end{cases}$$

則 I_A 為一隨機變數，它只取 1 與 0 兩個值，且 $P(I_A = 1) = P(A), P(I_A = 0) = 1 - P(A)$ 。指示函數是除了退化的隨機變數外，最簡單的隨機變數。利用指示函數，可將每一事件對應一隨機變數。求事件之機率，便可視為求隨機變數之機率。

2 分佈函數及機率密度函數

隨機變數已經是一函數，對一隨機變數 X ，我們又引出另一重要的函數，即累積分佈函數(cumulative distribution function)，通常簡稱為分佈

函數，又稱分布函數，或分配函數：

$$(3) \quad F_X(x) = P(X \leq x), x \in R.$$

如果不會混淆， $F_X(x)$ 也可只寫成 $F(x)$ 。對隨機變數 X ，給定一 $x \in R$ ， $F(x)$ 乃一機率值。由於我們常對形式為 $\{X \leq x\}$ 的事件之機率有興趣，所以特別以函數 $F(x)$ 表此機率值。一些常會用到的與 X 有關的機率值，都可藉由 F 表示出來。分佈函數可說是與隨機變數的關係極為密切之一函數。

分佈函數是一定義域為實數集合，對應域為區間 $[0, 1]$ 的函數。由機率空間，隨機變數，至分佈函數，當只給分佈函數時，源頭之機率空間為何，可能毫不清楚。自完全不同的機率空間，有可能會得到相同的分佈函數。

由於是以(3)式來定義分佈函數，這可解釋為何在上一節裡，我們曾提到，須滿足條件(1)才是隨機變數。否則若有一 $x \in R$ ，使得 $\{X \leq x\} \notin \mathcal{F}$ ，即 $\{X \leq x\}$ 非事件，因此便不知 $\{X \leq x\}$ 之機率，如此就得不到 $F(x)$ 了。

例6. 投擲一公正的銅板3次，令 X 表所得之正面數。則因 $P(X = 0) = 1/8$, $P(X = 1) = 3/8$, $P(X = 2) = 3/8$, $P(X = 3) = 1/8$ ，故

$$F(x) = \begin{cases} 0, & x < 0, \\ P(X = 0) = \frac{1}{8}, & 0 \leq x < 1, \\ P(X = 0) + P(X = 1) = \frac{1}{2}, & 1 \leq x < 2, \\ P(X = 0) + P(X = 1) + P(X = 2) = \frac{7}{8}, & 2 \leq x < 3, \\ \sum_{i=0}^3 P(X = i) = 1, & x \geq 3. \end{cases}$$

圖1 為 $F(x)$ 的圖形。

我們說明一下圖1。分佈函數 F ，乃定義在整個實數上，而非只定義在 X 取值的集合 $\Omega_1 = \{0, 1, 2, 3\}$ 。例如，

$$F(2.7) = P(X \leq 2.7) = P(X = 0, 1, 2) = P(X \leq 2) = \frac{7}{8}.$$

換句話說 $F(2.7) = F(2)$ 。事實上對 $2 \leq x < 3$, $F(x)$ 之值皆為 $7/8$ 。 F 的圖形，在 $\forall x_i \in \Omega_1$ ，有一跳升(jump)，跳升的高度即 $P(X = x_i)$ 。又 $x < 0$ 時，

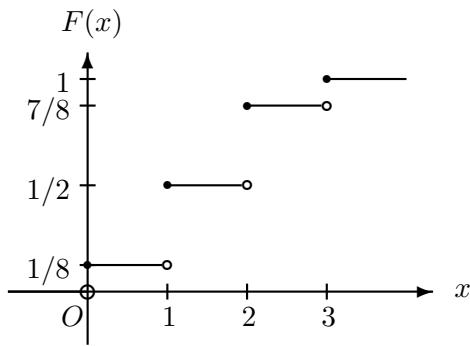


圖1 例6中 $F(x)$ 之圖形

$F(x) = 0$, 因 X 不會取負值。而 $x > 3$ 時, $F(x) = 1$, 因 X 不會取大於 3 之值。也可看出 F 的圖形為一階梯函數(step function), 並且是右連續(right continuous)。即

$$\lim_{t \downarrow x} F(t) = F(x), x \in R,$$

其中 $t \downarrow x$ 表 t 由 x 的右側漸減趨近至 x 。又 $t \uparrow x$ 表 t 由 x 的左側漸增趨近至 x 。

退化的隨機變數, 其分佈函數亦為階梯函數。即若 $X \equiv c$, 則 $F(x) = 0$, $x < c$, $F(x) = 1$, $x \geq c$ 。反之若 X 有前述分佈函數, 則知 $X \equiv c$ 。

我們將分佈函數具有的性質, 列成一定理。

定理2.1 設 F 為一分佈函數, 則有下述性質:

- (i) $0 \leq F(x) \leq 1, \forall x \in R$;
- (ii) F 為一非漸減函數;
- (iii) F 為一右連續函數;
- (iv) $\lim_{x \rightarrow -\infty} F(x) = 0$, 且 $\lim_{x \rightarrow \infty} F(x) = 1$ 。

在上述定理中, 條件(i)其實可以不用, 因(ii)與(iv)便導致(i)成立。不過我們還是寫出來, 使分佈函數的性質更清楚。

反之, 若一函數具有定理1中之(ii)-(iv)三個性質, 必為某一隨機變數之

分佈函數，見下定理，證明則略去。

定理2.2 設 G 為一非漸減且右連續之函數，並滿足 $\lim_{x \rightarrow -\infty} G(x) = 0$, $\lim_{x \rightarrow \infty} G(x) = 1$ 。則存在一隨機變數 X ，以 G 為其分佈函數。

由於定理2，任一非漸減、右連續，且滿足 $\lim_{x \rightarrow -\infty} G(x) = 0$, 及 $\lim_{x \rightarrow \infty} G(x) = 1$ 之函數，皆可視為分佈函數。不過定理2是針對存在性，事實上，以 G 為分佈函數之隨機變數並不唯一。讀者在上一節已看到，樣本空間不必須都是區間 $(0, 1)$ 。

如果我們只討論機率，便只須知隨機變數之分佈，機率空間並無關緊要。甚至有時隨機變數的“名字”亦不重要，稱為 X ，稱為 Y 皆可，出身(定義在那一機率空間)不同也沒關係。不同的隨機變數，可以有相同的分佈函數(見底下例9)。 X, Y, Z 等，在此不過是一個“名字”而已。

設隨機變數 X 之分佈函數為 F ，則對 $\forall a < b$ ，因 $\{X \leq a\} \subset \{X \leq b\}$ ，故由機率函數的性質得

$$\begin{aligned} P(a < X \leq b) &= P(\{X \leq b\} \setminus \{X \leq a\}) = P(X \leq b) - P(X \leq a) \\ &= F(b) - F(a). \end{aligned}$$

我們以 F 表示出一些與 X 有關之常見事件的機率如下：先令 $F(x-) = \lim_{t \uparrow x} F(t), x \in R$ ，表 F 在 x 之左極限值。如果 F 在 x 連續，則 $F(x-) = F(x)$ 。 $F(x) - F(x-)$ 表 F 之圖形在 x 跳升之高度。對任二 $a, b \in R$,

$$\begin{aligned} P(X = a) &= F(a) - F(a-), \\ P(X > a) &= 1 - F(a), \\ P(X \geq a) &= 1 - F(a-) = 1 - F(a) + P(X = a), \\ P(X \leq b) &= F(b), \\ P(X < b) &= F(b-) = F(b) - P(X = b). \end{aligned}$$

又對 $a < b$,

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

$$P(a \leq X < b) = F(b-) - F(a-) = F(b) - F(a) + P(X = a) - P(X = b)。$$

例7. 持續投擲一出現正面的機率為 p 之銅板, $0 < p < 1$, 直到出現一正面才停止。令 X 表總共之投擲數。則

$$(4) \quad P(X = x) = p(1-p)^{x-1}, x \geq 1。$$

因此對 $x = 1, 2, \dots$,

$$\begin{aligned} F(x) = P(X \leq x) &= \sum_{i=1}^x P(X = i) = \sum_{i=1}^x p(1-p)^{i-1} \\ &= 1 - (1-p)^x。 \end{aligned}$$

F 之圖形仍為階梯函數，在兩整數之間是水平的。一隨機變數，若具有這種分佈函數，稱為有**幾何分佈**(geometric distribution)。

有了 F , 可得 X 落在任一區間之機率。如

$$\begin{aligned} P(3.1 < X \leq 7.2) &= P(3 < X \leq 7) = F(7) - F(3) \\ &= (1 - (1-p)^7) - (1 - (1-p)^3) \\ &= (1-p)^3 - (1-p)^7。 \end{aligned}$$

本例亦顯示，對一分佈函數 F , 不一定存在 $-x \in R$, 使得 $F(x) = 1$ 。當然也不一定存在 $-x \in R$, 使得 $F(x) = 0$ 。

底下為分佈函數連續的例子。

例8. 設

$$F_1(x) = \begin{cases} 0, & x < 0, \\ x, & 0 \leq x < 1, \\ 1, & x \geq 1。 \end{cases} \quad F_2(x) = \begin{cases} 0, & x < 0, \\ 1 - e^{-\lambda x}, & x \geq 0。 \end{cases}$$

圖2分別給出 F_1 及 F_2 之圖形。 F_1 及 F_2 為連續函數，滿足定理1中之4個條件，故皆為分佈函數。分佈函數如 F_1 , 便稱有在區間 $(0, 1)$ 之**均勻分**

佈(uniform distribution), 以 $U(0, 1)$ 表之; 分佈函數如 F_2 , 便稱有參數 λ 之指數分佈(exponential distribution), 以 $E(\lambda)$ 表之, 其中 $\lambda > 0$ 。又我們也可定義在區間 (a, b) 之均勻分佈, 其中 $a < b$, 並以 $U(a, b)$ 表之, 即分佈函數 $F(x) = (x - a)/(b - a), x \in [a, b]$, 且 $F(x) = 0, x < a, F(x) = 1, x \geq b$ 。另外, 也可有 $U[a, b], U(a, b)$ 或 $U[a, b]$ 分佈。

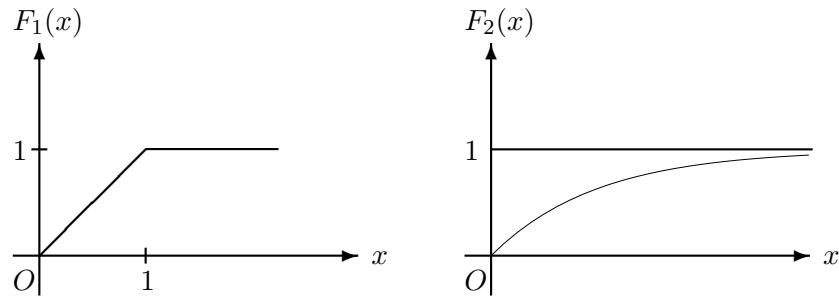


圖2 例8中 $F_1(x)$ 及 $F_2(x)$ 之圖形

隨機變數 X 之分佈函數 F 若為連續函數, 便稱 X 為連續型; 若 F 為階梯函數, 便稱 X 為離散型。也可稱分佈函數為連續型或離散型。不過也有既非連續型亦非離散型的隨機變數。例如, 令

$$F(x) = \begin{cases} \frac{1}{2} \frac{1}{1+e^{-x}}, & x < 0, \\ \frac{1}{2} + \frac{1}{2} \frac{1}{1+e^{-x}}, & x \geq 0. \end{cases}$$

F 滿足定理1中之4個條件, 故為分佈函數。但 F 之圖形並非階梯函數, 且除了在 $x = 0$ 有一高度為 $1/2$ 之跳升(所以 $P(X = 0) = 1/2$), 其餘地方為連續。故 F 既非連續型, 亦非離散型。

離散型隨機變數, 其分佈函數的圖形, 有跳升之處的集合, 必為可數的, 可能是一有限集合, 或可數的無限集合。

有時我們給一分佈函數“ $F(x), x > a$ ”, 其中 a 為一常數, 就表 $F(x) = 0, \forall x \leq a$ 。又若說有一分佈函數“ $F(x), a < x < b$ ”, 就表 $F(x) = 0, x \leq a$, 且 $F(x) = 1, x \geq b$ 。其他形式(如 $F(x), x < b$)也有類似的說明。

要注意的是, 不但在同一樣本空間, 可以定義出不同的隨機變數, 而分佈函數卻相同, 在不同的樣本空間, 亦可分別定義隨機變數, 且有相同的分佈函數。

我們再給二隨機變數分佈相同(identically distributed)之定義。

定義1. 二隨機變數 X, Y , 若其分佈函數相同, 即滿足

$$(5) \quad P(X \leq x) = P(Y \leq x), x \in R,$$

則稱分佈相同, 並以 $X \stackrel{d}{=} Y$ 表之。

設以 F, G 分別表 X 及 Y 之分佈函數。 X 與 Y 分佈相同, 表 $F(x) = G(x)$, $\forall x \in R$ 。也可說 X 與 Y 有共同的分佈。但分佈相同與隨機變數相同是不一樣的, 甚至二差異很大的隨機變數, 都可有相同的分佈函數。我們以下二例來說明。

例9. 投擲一公正的銅板3次, 令 X 表所得之正面數, Y 表所得之反面數。則當然 $X \neq Y$ 。因若 $X = 0$ 則 $Y = 3$ 。事實上, 可看出 X 與 Y 二“函數”不會有相等的時候, 即 $X(\omega) \neq Y(\omega)$, $\forall \omega \in \Omega$, 其中 Ω 見例1(如當 $\omega = \text{正正正}$, 則 $X(\omega) = 3 \neq 0 = Y(\omega)$)。但因

$$P(X = i) = P(Y = i), i = 0, 1, 2, 3,$$

故 X 與 Y 有相同的分佈函數, 即 $X \stackrel{d}{=} Y$ 。

例10. 投擲一公正的銅板3次, 令 Z 表所得之正面數。投擲一公正的骰子3次, 令 W 表所得點數為偶數的次數。 Z 與 W 為兩個不相干的隨機變數, 二者當然不等。

隨機變數乃函數, 而二函數 f 與 g 相等的定義是要滿足

- (i) f 與 g 有相同的定義域,
- (ii) 對每一定義域中的 x , $f(x) = g(x)$ 。

現因 Z 的定義域為例1中之 Ω , 共有8個元素, 而 W 之定義域為

$$\{111, 112, \dots, 666\},$$

共有216個元素, 其中 ijk 表投擲骰子第1次得 i , 第2次得 j , 第3次得 k , $1 \leq$

$i, j, k \leq 6$, W 與 Z 之定義域不同, 故 $Z \neq W$ 。但明顯可看出

$$P(Z = i) = P(W = i), i = 0, 1, 2, 3,$$

故 $Z \stackrel{d}{=} W$ 。

在例9中, X 與 Y 雖為不同的隨機變數(只是分佈相同), 但二者的關係卻知道, 即 $X + Y = 3$, 或者說 $Y = 3 - X$ 。我們也可求諸如 $X > Y$, $X = Y + 1$ 等事件之機率。但在例10中, $Z = 3$ 時, W 是多少, 是完全不知道的。而事件 $Z > W$, 或 $Z = W + 1$ 的機率, 也無法求得。這是屬於兩個隨機變數的問題, 要知道 Z 與 W 之聯合分佈(見第5節)才行。光知道 Z 的分佈, 及 W 的分佈, 並無法求同時與 Z, W 有關的機率。

雖 $X \stackrel{d}{=} Y$ 時, 不一定導致 $X = Y$, 但 $X = Y$, 卻必導致 $X \stackrel{d}{=} Y$ 。此因 $X = Y$ (二函數相等), 表 $X(\omega) = Y(\omega)$, $\forall \omega \in \Omega$, 故對 $\forall x \in R$,

$$P(X \leq x) = P(\{\omega | X(\omega) \leq x\}) = P(\{\omega | Y(\omega) \leq x\}) = P(Y \leq x)。$$

二隨機變數 X, Y , 亦有可能滿足諸如 $X < Y$, $X < Y + 1$, $X > 3Y$, 或 $X^2 = Y$ 等。例如, 若令 $Y = X + 1$, 則有 $X < Y$ 。記住隨機變數即函數, 因此函數會有的性質或關係, 隨機變數自然也可以有。

對一隨機變數 X , 除了伴隨分佈函數 F , 亦有一與其關係密切的函數, 即 **機率密度函數**(probability density function), 或是 **機率質量函數**(probability mass function), 前者是對連續型, 後者是對離散型。不過為了簡便, 通常我們不分連續或離散, 皆說是機率密度函數。底下我們給其定義。

設 X 為一隨機變數, 以 F 為分佈函數。若 X 為離散型, 則下述函數 f (若為區隔可寫 f_X), 便稱為 X 之機率密度函數:

$$(6) \quad f(x) = P(X = x), x \in R。$$

由於離散型隨機變數, 其分佈函數的圖形, 有跳升之處的集合為可數的, 而此集合就是使 $P(X = x)$ 為正之所有 x 的集合。設以 C 表此集

合，則對 $\forall x \notin C$, $f(x) = 0$ 。因此離散型的機率密度函數，有時表示成 $f(x), x \in C$, 其中 C 為某一可數的集合，可能是 $\{1, 2, \dots, 10\}$, 也可能是非負整數的集合 $\{0, 1, 2, \dots\}$ 等。至於 $x \notin C$ 時的 $f(x)$ 往往不提，因其值皆為0。所以即是將此機率密度函數的定義域取成 C 。可看出對一實數上的集合 A ,

$$P(A) = P(X \in A) = \sum_{x \in A \cap C} f(x),$$

且

$$F(x) = \sum_{t \leq x, t \in C} f(t), x \in R.$$

例11. 設隨機變數 X 之機率密度函數為

$$f(x) = \begin{cases} (8/15)(1/2)^x, & x = 0, 1, 2, 3, \\ 0, & \text{其他} . \end{cases}$$

則可求出其分佈函數為

$$F(x) = \begin{cases} 0, & x < 0, \\ 8/15, & 0 \leq x < 1, \\ 12/15, & 1 \leq x < 2, \\ 14/15, & 2 \leq x < 3, \\ 1, & x \geq 3. \end{cases}$$

為一階梯函數。

又在求 $F(2.5)$ 時，可依定義得

$$\begin{aligned} F(2.5) &= \sum_{x \leq 2.5} f(x) = f(0) + f(1) + f(2) \\ &= \frac{8}{15} + \frac{4}{15} + \frac{2}{15} = \frac{14}{15}, \end{aligned}$$

或利用已求出之 $F(x)$ ，因 $2.5 \in [2, 3]$ ，故 $F(2.5) = 14/15$ 。

圖3給出 $f(x)$ 及 $F(x)$ 之圖形。

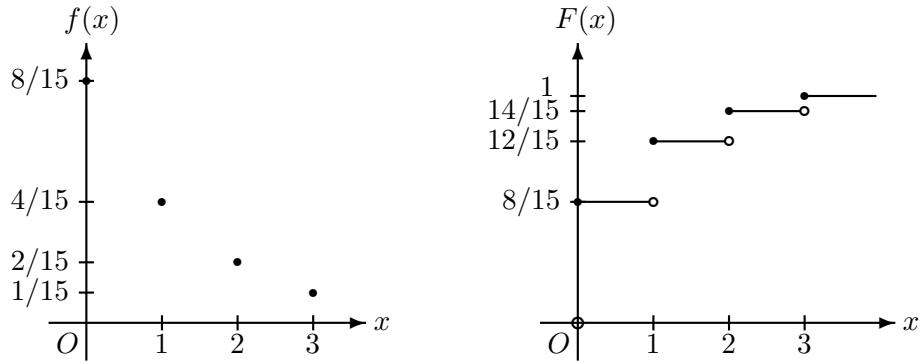


圖3 例11中 $f(x)$ 及 $F(x)$ 之圖形

離散型機率密度函數之圖形，有時以線段表之。而對只取整數值之隨機變數，其機率密度函數的圖形，有時以一些小長方形表示，每一小長方形之底部中點為取值處，高度為該點之機率，因此小長方形面積和為1。這樣表示機率密度函數的圖形，稱為直方圖(histogram)。例11中之 $f(x)$ 亦可繪成如圖4中之二圖，右圖即直方圖。

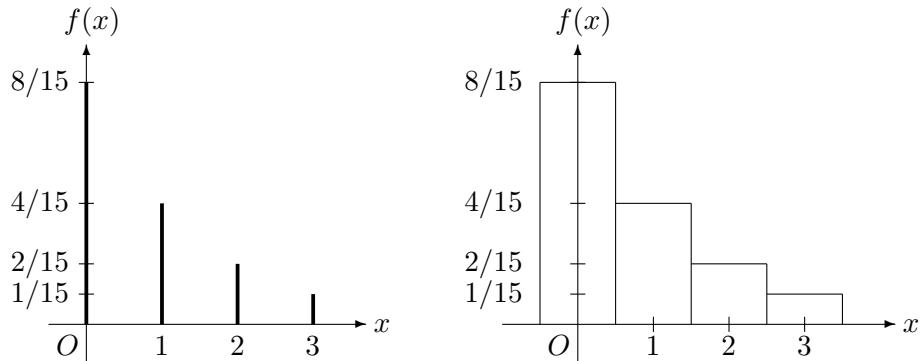


圖4 例11中 $f(x)$ 之圖形

其次若 X 為連續型，則其機率密度函數，乃定義為滿足下式之非負函數 f :

$$(7) \quad F(x) = \int_{-\infty}^x f(t)dt, x \in R.$$

由定理1，因 $\lim_{x \rightarrow \infty} F(x) = 1$ ，故知 f 除了非負之外，尚須滿足

$$(8) \quad \int_{-\infty}^{\infty} f(x)dx = 1.$$

即 $f(x)$ 之圖形與 x 軸間之面積為 1。

對連續型的隨機變數 X ，由於 $P(X = x) = 0, \forall x \in R$ ，即 X 取任一定值的機率為 0。故在求 X 落在某一區間的機率時，該區間是否包含端點是無關緊要的。即對 $a < b$ ，

$$\begin{aligned} P(a < X < b) &= P(a \leq X < b) = P(a \leq X \leq b) \\ &= P(a < X \leq b) = F(b) - F(a). \end{aligned}$$

若以機率密度函數表示，上述任一機率皆等於

$$P(a < X < b) = \int_{-\infty}^b f(t)dt - \int_{-\infty}^a f(t)dt = \int_a^b f(t)dt.$$

連續型隨機變數，其機率密度函數，也可有寫成 $f(x), c \leq x \leq d$ ，的型式，即表 $f(x) = 0, \forall x > d$ 或 $x < c$ ，即所對應的隨機變數，取值不會大於 d 也不會小於 c 。

又由微積分基本定理(fundamental theorem of calculus)，若 f 為連續函數，則由(7)式，

$$(9) \quad F'(x) = f(x), x \in R.$$

可藉由上式得到此時之機率密度函數。又二隨機變數，若有相同的機率密度函數，則其分佈相同。

例12. 在例8中，對應 F_1 及 F_2 之機率密度函數分別為

$$f_1(x) = \begin{cases} 0, & x \leq 0, \\ 1, & 0 < x < 1, \\ 0, & x \geq 1; \end{cases} \quad f_2(x) = \begin{cases} 0, & x < 0, \\ \lambda e^{-\lambda x}, & x \geq 0. \end{cases}$$

或簡單地寫成 $f_1(x) = 1, 0 < x < 1$, $f_2(x) = \lambda e^{-\lambda x}, x \geq 0$ 。對連續型的隨機變數，機率密度函數在有限個點的值改變，是不用在意的。因此前述 f_1 寫成

$$f_1(x) = 1, 0 \leq x < 1, \quad f_1(x) = 1, 0 < x \leq 1, \quad \text{或} f_1(x) = 1, 0 \leq x \leq 1,$$

等皆可。這3個 f_1 亦皆滿足 $F_1(x) = \int_{-\infty}^x f_1(t)dt, x \in R$, 因此皆可當做對應 F_1 之機率密度函數。

必須一提的是，連續型的分佈不一定有機率密度函數，此因一連續函數不一定可微。也就是有可能分佈函數 F 為連續，但不存在函數 f ，使得(7)式成立。

由分佈函數可得到機率密度函數，反之亦有下述定理。

定理2.3 一函數 f 若滿足下述二條件，必為某一隨機變數之機率密度函數：

- (i) $f(x) \geq 0, \forall x \in R$,
- (ii) $\sum_x f(x) = 1$ (離散型)，或 $\int_{-\infty}^{\infty} f(x)dx = 1$ (連續型)。

由上述定理知，機率密度函數是可以很容易得到的，對一非負的函數 g ，且 $\sum_x g(x)$ (離散型)，或 $\int_{-\infty}^{\infty} g(x)dx$ 為正且有限，則經除以該和或積分的值，便立即可得一機率密度函數，見下例。

例13. 設 $g(x) = 3^{-x}, x = 1, 2, 3, \dots$ 。因 $\sum_{x=1}^{\infty} g(x) = 1/2$ ，故 $f(x) = 2g(x) = 2 \cdot 3^{-x}, x = 1, 2, 3, \dots$ ，即成為一機率密度函數。

另外，設 $g_1(x) = xe^{-3x}, x > 0$ 。因 $\int_0^{\infty} xe^{-3x}dx = 1/9$ ，故 $f_1(x) = 9g_1(x) = 9xe^{-3x}, x > 0$ ，亦成為一機率密度函數。假設隨機變數 X 以 f_1 為機率密度函數，則分佈函數 $F(x) = P(X \leq x) = \int_0^x f_1(u)du = 1 - e^{-3x} - 3xe^{-3x}, x \geq 0$ 。

對連續型的隨機變數，其機率密度函數 $f(x)$ 與 x 軸間之面積等於1；對離散型的隨機變數，其機率密度函數之高度和等於1。通常我們較少去繪隨機變數的圖形(雖然此為一函數)，但分佈函數及機率密度函數的圖形倒

是常繪的。

對一隨機變數 X , 以 $F(x)$ 為分佈函數, $f(x)$ 為機率密度函數, 有時可以 $X \sim F(x)$ 或 $X \sim f(x)$ 表之。至於若 $X \stackrel{d}{=} Y$, 也可以 $X \sim Y$ 表之。對一隨機變數 X , 我們常會說, X 遵循某一分佈, 或說 X 之機率法則為…。分佈就如同隨機變數, 機率上的法則(law), 是隨機變數該遵循的。而給定機率密度函數, 或分佈函數, 或任何其他可以唯一決定分佈函數之轉換(見第4節)等, 皆稱為給定分佈, 或說決定分佈。

3 變數代換

在很多試驗裡, 對一隨機變數 X , 有時我們可能會對 X 之某一函數有興趣。譬如說量測得到圓的半徑 X , 但我們想知道圓的面積 $Y = \pi X^2$ 。即使不論實務上的需要, 在第1節我們已指出, 在數學裡我們常會討論與一變數有關的函數之性質或行為。對一隨機變數 X , 有時我們會想知道它的一個函數 $Y = g(X)$ 的行為。 Y 便稱為 X 之變數代換(change of variable)。而由 X 至 $Y = g(X)$, 也可視為一種隨機變數之轉換(transformation of a random variable)。 Y 仍為一隨機變數。若 X 的分佈知道, 則因 Y 的值是由 X 的值所決定, 故 Y 的分佈, 可由所給之 X 的分佈來決定。

對每一實數的子集合 A ,

$$(10) \quad P(Y \in A) = P(g(X) \in A) = P(X \in g^{-1}(A)) .$$

在此

$$g^{-1}(A) = \{x | x \in R, g(x) \in A\} .$$

對於新的隨機變數 Y , 由(10)式, 欲求 Y 落在某一集合 A 之機率, 仍要回到關於 X 的機率。但若我們求出 Y 的分佈函數(或機率密度函數), 當然就可以不用理會 X 了。

若 X 為離散型的隨機變數, 則 $Y = g(X)$ 的機率密度函數, 只要留意由 X 至 Y 的變換是否為1-1(等價於 g 是否為嚴格單調函數), 則藉由(10)式,

通常可很快地得到。底下為一典型的例子。

例14. 設 X 為一離散型的隨機變數，且機率密度函數為

$$f_X(x) = \begin{cases} 0.15, & x = 0, 3, \\ 0.20, & x = 1, 2, \\ 0.30, & x = 4, \\ 0, & \text{其他。} \end{cases}$$

令 $Y = X^2, Z = (X - 2)^2$ 。我們分別來決定 Y 及 Z 之分佈。

首先 X 之可能的值為 $0, 1, 2, 3, 4$ ， Y 之可能的值則為 $0, 1, 4, 9, 16$ 。因 X 只取非負的值，故由 X 至 Y 的變換為 $1 - 1$ (雖 $g(x) = x^2, x \in R$ ，並非嚴格單調函數，但在 $x \geq 0$ 處， g 為嚴格單調)。又

$$P(Y = y) = P(X^2 = y) = P(X = \sqrt{y}), y = 0, 1, 4, 9, 16.$$

故得 Y 之機率密度函數為

$$f_Y(y) = P(Y = y) = \begin{cases} 0.15, & y = 0, \\ 0.20, & y = 1, \\ 0.20, & y = 4, \\ 0.15, & y = 9, \\ 0.30, & y = 16, \\ 0, & \text{其他。} \end{cases}$$

可驗證 $\sum_y f_Y(y)$ 仍等於1。

其次 Z 之可能的值為 $0, 1, 4$ 。 $X = 0$ 及 4 ，皆對應 $Z = 4$ ； $X = 1$ 及 3 ，皆對應 $Z = 1$ ； $X = 2$ ，則對應 $Z = 0$ 。故由 X 至 Z ，並非 $1 - 1$ 的變換。 Z 之機率密度函數為

$$f_Z(z) = P(Z = z) = \begin{cases} f_X(2) = 0.20, & z = 0, \\ f_X(1) + f_X(3) = 0.35, & z = 1, \\ f_X(0) + f_X(4) = 0.45, & z = 4. \end{cases}$$

可驗證 $\sum_z f_Z(z)$ 仍等於 1。

底下再給一例。

例15. 設隨機變數 X 之機率密度函數為

$$f(x) = \frac{1}{31}2^{4-x}, x = 0, 1, 2, 3, 4.$$

令 $Y = X^2 + 1$ 。此為由 X 至 Y 之 $1 - 1$ 變換， $X = \sqrt{Y - 1}$ 。 Y 取值在 $1, 2, 5, 10, 17$ 。故 Y 之機率密度函數為

$$f_Y(y) = \frac{1}{31}2^{4-\sqrt{y-1}}, y = 1, 2, 5, 10, 17.$$

其次令 $Z = g(X) = X^3 - 3X^2 + X + 2$ 。則因

$$g(0) = 2, \quad g(1) = 1, \quad g(2) = 0, \quad g(3) = 5, \quad g(4) = 22,$$

故此仍為由 X 至 Z 之 $1 - 1$ 變換。雖不易給出 $X = g^{-1}(Z)$ 之 g^{-1} 的型式，但仍可寫出 Z 之機率密度函數如下：

$$\begin{aligned}f_Z(0) &= P(X = 2) = \frac{4}{31}, \\f_Z(1) &= P(X = 1) = \frac{8}{31}, \\f_Z(2) &= P(X = 0) = \frac{16}{31}, \\f_Z(5) &= P(X = 3) = \frac{2}{31}, \\f_Z(22) &= P(X = 4) = \frac{1}{31}.\end{aligned}$$

要知所謂函數，只要每一定義域中的元素，在對應域中恰有一元素與其對應即可，不一定要能給出一個適用定義域中每一元素的型式。

其次我們給二連續型隨機變數的例子。

例16. 設隨機變數 X 有 $\mathcal{U}(0,1)$ 分佈。即其機率密度函數為 $f(x) = 1, 0 < x < 1$ 。令 $Y = -\lambda^{-1} \log(1 - X)$ ，其中 $\lambda > 0$ 為一常數。機率與統計裡出現

的對數符號 \log , 通常為自然對數, 即以 e 為底。此為一由 X 至 Y 之 $1 - 1$ 變換。由於 X 介於 $0, 1$ 之間, 故 Y 取值在 $(0, \infty)$ 。則對 $\forall y > 0$,

$$\begin{aligned} F_Y(y) = P(Y \leq y) &= P(-\lambda^{-1} \log(1 - X) \leq y) = P(\log(1 - X) \geq -\lambda y) \\ &= P(X \leq 1 - e^{-\lambda y}) = 1 - e^{-\lambda y}, y > 0. \end{aligned}$$

因此 Y 之機率密度函數為

$$f_Y(y) = \frac{dF_Y(y)}{dy} = \begin{cases} \lambda e^{-\lambda y}, & y > 0, \\ 0, & y \leq 0. \end{cases}$$

即 Y 有 $\mathcal{E}(\lambda)$ 分佈。

例17. 設隨機變數 X 之機率密度函數為

$$f_X(x) = \frac{2}{\pi(1 + x^2)}, x > 0.$$

令 $Y = 1/X$ 。則此為一由 X 至 Y 之 $1 - 1$ 變換, 且 Y 取值在 $(0, \infty)$ 。我們想決定 Y 之機率密度函數。

對 $\forall y > 0$,

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(1/X \leq y) = P(X \geq 1/y) = P(X > 1/y) \\ &= 1 - P(X \leq 1/y) = 1 - F_X(1/y). \end{aligned}$$

因此

$$\begin{aligned} f_Y(y) &= \frac{dF_Y(y)}{dy} = f_X\left(\frac{1}{y}\right) \cdot \frac{1}{y^2} = \frac{2}{\pi(1 + 1/y^2)} \cdot \frac{1}{y^2} \\ &= \frac{2}{\pi(1 + y^2)}, y > 0. \end{aligned}$$

由於 X 與 Y 之機率密度函數相同, 故 X 與 Y 有相同的分佈, 即 $X \stackrel{d}{=} Y$ 。對此特別的分佈, 雖經過一倒數的變換, 所得之新隨機變數, 其分佈卻未改變。

在上述推導中，由於只是要求 Y 之機率密度函數，所以我們並未將 $F_Y(y)$ 明確地寫出。事實上

$$\begin{aligned} F_Y(y) &= 1 - F_X(1/y) = 1 - \int_0^{1/y} f_X(x)dx \\ &= 1 - \int_0^{1/y} \frac{2}{\pi(1+x^2)} dx = 1 - \frac{2}{\pi} \arctan\left(\frac{1}{y}\right), y > 0. \end{aligned}$$

將此 $F_Y(y)$ 對 y 微分，便得到前述 $f_Y(y)$, $y > 0$ 。

在例17的推導過程中，有

$$f_Y(y) = f_X\left(\frac{1}{y}\right) \cdot \frac{1}{y^2}.$$

即 Y 之機率密度函數，可將 X 之機率密度函數中的參數 x ，以 $1/y$ 取代，再乘上 $1/y$ 對 y 微分的絕對值。而由 $Y = g(X) = 1/X$ ，解出

$$X = g^{-1}(Y) = \frac{1}{Y}.$$

故 $f_Y(y)$ 可寫成

$$f_Y(y) = f_X(g^{-1}(y)) \left| \frac{d}{dy}g^{-1}(y) \right|.$$

上述這些討論與觀察，便引出底下兩個一般的定理。

定理3.4 設隨機變數 X 之分佈函數為 F_X ，機率密度函數為 f_X 。令 $Y = g(X)$, Y 之分佈函數以 F_Y 表之。又令

$$(11) \quad \Omega_1 = \{x | f_X(x) > 0\},$$

$$(12) \quad \Omega_2 = \{y | \text{存在 } x \in \Omega_1, \text{使得 } y = g(x)\}.$$

- (i) 若 g 在 Ω_1 為嚴格漸增函數，則 $F_Y(y) = F_X(g^{-1}(y))$, $\forall y \in \Omega_2$;
- (ii) 若 g 在 Ω_1 為嚴格漸減函數，則 $F_Y(y) = 1 - F_X(g^{-1}(y)-)$, $\forall y \in \Omega_2$ 。

定理4對連續及離散型的隨機變數皆適用。當 Y 之機率密度函數為

連續，則利用定理4，可由微分分佈函數而得。我們列成一定理。

定理3.5 設隨機變數 X 之機率密度函數為 f_X 。令 $Y = g(X)$ ，其中 g 為一嚴格單調函數， Ω_1 及 Ω_2 分別定義在(11)及(12)式中。設 f_X 在 Ω_1 連續，且 g^{-1} 在 Ω_2 有一連續的導數，則 Y 之機率密度函數為

$$(13) \quad f_Y(y) = f_X(g^{-1}(y)) \left| \frac{d}{dy} g^{-1}(y) \right|, \quad y \in \Omega_2,$$

且 $f_Y(y) = 0, y \notin \Omega_2$ 。

例18. 設 X 有 $\mathcal{E}(\lambda)$ 分佈。令 $Y = \sqrt{X}$ 。則 $\Omega_1 = \Omega_2 = (0, \infty)$ ，且 X 之機率密度函數 $f_X(x) = \lambda e^{-\lambda x}, x > 0$ ，在 Ω_1 中連續； $g^{-1}(y) = y^2$ 在 Ω_2 之導數 $2y$ 為連續。故 Y 之機率密度函數為 $f_Y(y) = f(y^2) \cdot 2y = 2\lambda y e^{-\lambda y^2}, y > 0$ 。 Y 稱為具有參數 λ 之瑞萊分佈(Rayleigh distribution)。

在做變數代換時，函數 g 有時不為嚴格單調，因此定理5就不適用。但往往會有 g 在一個個的集合中，分別為嚴格單調(想想諸如多項函數、正弦及餘弦函數的圖形)，可參考一般初等的機率或統計的書。因此在每一個集合中，皆可解出 $X = g^{-1}(Y)$ ，則仍有辦法求出 Y 之分佈。

4 期望值

對一隨機變數，我們常想粗略地知道其值究竟多大，**期望值**(expectation, 或稱expected value, mean)，就是常被拿來扮演這種以一單一的值，來代表一隨機現象中之變數大小的角色。

設隨機變數 X 之機率密度函數為 f ，則其期望值以 $E(X)$ 表示，定義為

$$(14) \quad E(X) = \begin{cases} \int_{-\infty}^{\infty} xf(x)dx, & \text{連續型,} \\ \sum_x xf(x), & \text{離散型,} \end{cases}$$

只要上述積分或和存在。此處 $\sum_x xf(x)$ 表對所有可能的 x (即 $f(x) \neq 0$)相加。通常以 μ_X (或只以 μ)表 $E(X)$ 。

假設有10個數: 1, 1, 2, 2, 2, 3, 3, 3, 4, 4, 則其平均為

$$\frac{1}{10}(1 + 1 + 2 + 2 + 2 + 3 + 3 + 3 + 4 + 4) = 2.5。$$

由於數字中有重複: 有2個1, 3個2, 3個3, 2個4, 所以平均亦可表為

$$\frac{1}{10}(1 \cdot 2 + 2 \cdot 3 + 3 \cdot 3 + 4 \cdot 2) = 2.5,$$

所得相同。第二種作法是我們常採用的, 特別是在數字較多或較大時。又上式左側可改寫為

$$1 \cdot \frac{2}{10} + 2 \cdot \frac{3}{10} + 3 \cdot \frac{3}{10} + 4 \cdot \frac{2}{10},$$

其中 $2/10, 3/10, 3/10, 2/10$, 可分別視為10個數字中, 1, 2, 3, 4所佔的份量。所以第二種作法乃是一種加權平均。隨機變數期望值的定義, 便是基於加權平均的想法。這點由離散型隨機變數期望值的定義, 特別可以看出來。

至於 X 之一函數 $g(X)$ 的期望值, 則定義為

$$(15) \quad E(g(X)) = \begin{cases} \int_{-\infty}^{\infty} g(x)f(x)dx, & \text{連續型,} \\ \sum_x g(x)f(x), & \text{離散型。} \end{cases}$$

亦可經由變數代換, 先求出 $Y = g(X)$ 之機率密度函數, 再利用(14)式而求得 $E(Y)$ 。

底下給幾個例子。

例19. 設離散型隨機變數 X 之機率密度函數為

$$\begin{aligned} f(0) &= \frac{1}{16}, & f(1) &= \frac{2}{16}, & f(2) &= \frac{3}{16}, & f(3) &= \frac{4}{16}, \\ f(4) &= \frac{4}{16}, & f(5) &= \frac{1}{16}, & f(6) &= \frac{1}{16}. \end{aligned}$$

則

$$E(X) = \sum_{x=0}^6 xf(x) = \frac{47}{16}。$$

又

$$E((X - 3)^2) = \sum_{x=0}^6 (x - 3)^2 f(x) = \frac{37}{16}.$$

在求 $E((X - 3)^2)$ 時，也可利用變數代換。令 $Y = (X - 3)^2$ 。則 Y 取值 0, 1, 4, 9，且

$$\begin{aligned}f_Y(0) &= P(X = 3) = \frac{4}{16}, \\f_Y(1) &= P(X = 2) + P(X = 4) = \frac{7}{16}, \\f_Y(4) &= P(X = 1) + P(X = 5) = \frac{3}{16}, \\f_Y(9) &= P(X = 0) + P(X = 6) = \frac{2}{16}.\end{aligned}$$

故

$$E((X - 3)^2) = E(Y) = \sum_y y f_Y(y) = \frac{37}{16}.$$

其中 \sum 是對所有的 y 相加，即 0, 1, 4, 9。

例 20. 設隨機變數 X 之機率密度函數為 $f(x) = 2x, x \in [0, 1]$ 。則

$$\begin{aligned}E(X) &= \int_0^1 x \cdot 2x dx = \int_0^1 2x^2 dx = \frac{2}{3}, \\E(X^2) &= \int_0^1 x^2 \cdot 2x dx = \int_0^1 2x^3 dx = \frac{1}{2}.\end{aligned}$$

另外，亦可利用變數代換。令 $Y = X^2$ ，先求出 Y 之機率密度函數為

$$g(y) = 2\sqrt{y} \cdot \frac{1}{2\sqrt{y}} = 1, y \in [0, 1].$$

如此

$$E(X^2) = E(Y) = \int_0^1 y \cdot 1 dy = \frac{1}{2},$$

仍得到相同的結果。

例21. 在微積分裡有 $\sum_{i=1}^{\infty} 1/i^2 = \pi^2/6$ 。故

$$(16) \quad f(i) = \frac{6}{\pi^2} \frac{1}{i^2}, i = 1, 2, \dots,$$

為一機率密度函數。但因 $\sum_{i=1}^{\infty} 1/i = \infty$, 故若隨機變數 X 之機率密度函數如(16)式, 則 X 之期望值不存在。

另外, 因 $\sum_{i=1}^{\infty} 1/i^4 = \pi^4/90$, 故

$$(17) \quad g(i) = \frac{90}{\pi^4} \frac{1}{i^4}, i = 1, 2, \dots,$$

為一機率密度函數。又設隨機變數 Y 之機率密度函數如(17)式所給。則

$$E(Y) = \frac{90}{\pi^4} \sum_{i=1}^{\infty} \frac{1}{i^3} < \infty,$$

$$E(Y^2) = \frac{90}{\pi^4} \sum_{i=1}^{\infty} \frac{1}{i^2} = \frac{90}{\pi^4} \frac{\pi^2}{6} = \frac{15}{\pi^2} < \infty.$$

即 $E(Y)$ 及 $E(Y^2)$ 皆存在。當然 $E(Y^3)$ 便不存在了。

例22. 設隨機變數 X 有標準的柯西分佈(Cauchy distribution,, Augustin-Louis Cauchy, 1789-1857, 為法國著名數學家), 以 $\mathcal{C}(0, 1)$ 表之。即其機率密度函數為

$$f(x) = \frac{1}{\pi(1+x^2)}, x \in R.$$

則 X 之期望值不存在。此因

$$E(X) = \int_{-\infty}^{\infty} x \cdot \frac{1}{\pi(1+x^2)} dx,$$

為一瑕積分(improper integral)。而依定義, 此瑕積分存在, 若且唯若

$$\int_0^{\infty} \frac{x}{\pi(1+x^2)} dx, \quad \int_{-\infty}^0 \frac{x}{\pi(1+x^2)} dx$$

皆要存在。但此二積分皆不存在，分別為 ∞ 及 $-\infty$ 。故 $E(X)$ 不存在。

由上述瑕積分存在的定義，可看出 $E(X)$ 存在，若且唯若 $E(|X|)$ 存在。期望值有不少性質。例如，一有界的(bounded)隨機變數，期望值必存在。在此對一隨機變數 X ，若存在一常數 $M > 0$ ，使得 $P(|X| \leq M) = 1$ ，便稱該隨機變數為有界的。若 X 有 $\mathcal{U}(0, 1)$ 分佈，便為有界；有 $\mathcal{C}(0, 1)$ 分佈，則非有界。我們再列出一些性質如下。

定理4.6 設 X 為一隨機變數， a, b, c 為常數， g_1, g_2 為二函數，使得 $E(g_1(X))$ ， $E(g_2(X))$ 皆存在。則

- (i) $E(ag_1(X) + bg_2(X) + c) = aE(g_1(X)) + bE(g_2(X)) + c$;
- (ii) 若 $g_1(x) \geq 0, \forall x \in R$ ，則 $E(g_1(X)) \geq 0$;
- (iii) 若 $g_1(x) \geq g_2(x), \forall x \in R$ ，則 $E(g_1(X)) \geq E(g_2(X))$;
- (iv) 若 $a \leq g_1(x) \leq b, \forall x \in R$ ，則 $a \leq E(g_1(X)) \leq b$ 。

由上定理之(i)，特別地，只要 $E(X)$ 存在，則

$$(18) \quad E(aX + b) = aE(X) + b, \quad E(b) = b.$$

即一常數之期望值等於該常數。由於 $E(X)$ 為一常數(已非隨機了)，故其期望值仍為本身。即 $E(E(X)) = E(X)$ 。

期望值這個名詞也許會令有些人感到困擾。投擲一公正的骰子一次，令 X 表所得之點數。則 X 之機率密度函數為 $f(x) = 1/6, x = 1, 2, \dots, 6$ 。

因此

$$E(X) = \sum_{i=1}^6 i \cdot \frac{1}{6} = \frac{21}{6} = 3.5.$$

投擲一骰子，點數之期望值為3.5。點數為整數，無論怎麼投擲都得不到3.5。那怎會期望得到3.5呢？

就暫且不要去想期望值字面上的含義。不過期望值是一隨機變數之“最佳”常數的代表值。所謂最佳，指的是誤差平方的期望值最小。見下

定理。

定理4.7 設隨機變數 X 滿足 $E(X^2) < \infty$ 。則對所有 $a \in R$, $E((X - a)^2)$ 之極小值發生在 $a = E(X)$ 處。

果園裡生產的蘋果，大小頗有差異。有人問你，蘋果每個重量大約是多少，如何回答呢？人們常想以一常數 a 來代表一隨機變數 X 。很難說那一個 a 最好，誤差 $X - a$ 仍是隨機的。但在誤差平方 $(X - a)^2$ 之期望值最小下，上定理指出，期望值 $E(X)$ 便是最好的選擇。

其次我們定義動差(moment)。設 n 為一整數，則若 $E(X^n)$ 存在，便稱此為隨機變數 X 之 n 次動差。而 $E((X - \mu)^n)$ 稱為 X 的 n 次中心動差(nth central moment)，其中 $\mu = E(X)$ 。特別地，二次中心動差稱為 X 的變異數(variance)，以 σ_X^2 , $\text{Var}(X)$ 或簡單地以 σ^2 表之，即

$$(19) \quad \text{Var}(X) = E((X - E(X))^2)。$$

$\text{Var}(X)$ 之正的平方根，以 σ_X 或 σ 表之，稱為 X 之標準離差(standard deviation)，或標準差、均方差。另外，如同期望值，對於 n 次動差，仍有 $E(X^n)$ 存在，若且唯若 $E(|X|^n)$ 存在。

在機率論裡我們引進了隨機變數的概念。例如，學生不再如小學的練習裡，每位體重40公斤，求25位學生的總體重，而是讓每位學生的體重有一機率分佈。雖然這樣的模式較合理，但因無法掌握隨機的量之大小，我們才又想要有一代表值。由於具有很多好的性質，期望值遂常被拿來當做隨機變數之代表值。期望值像是隨機變數分佈之一個核心，隨機變數可能取的值，散佈在期望值的左右。其他亦常被拿來當做隨機變數之代表值的尚有中位數(median)及眾數(mode)等。眾數早期稱為密集數。在此一實數 m 若滿足

$$(20) \quad P(X \leq m) \geq \frac{1}{2}, \quad \text{且} P(X \geq m) \geq \frac{1}{2},$$

便稱為隨機變數 X (或其分佈)之一中位數。依此定義中位數不一定唯一。當然如果 X 之分佈函數為連續且嚴格漸增，則中位數便唯一。此時

中位數為唯一滿足 $F(x) = 0.5$ 之 x 。若 X 之分佈對稱於 m ，則 X 之中位數為 m 。另外，若 $f(a)$ 為 X 之機率密度函數的一絕對極大值，便稱 a 為 X (或其分佈)之一眾數。對 X 為離散型的隨機變數，其眾數表 X 最可能取的值。眾數不一定存在也不一定唯一。而且中位數及眾數有時雖存在但卻不易求出。

例23. 設 X 為一離散型的隨機變數，且 $P(X = 0) = 1/4$, $P(X = 1) = 1/2$, $P(X = 2) = 1/4$ 。則 X 有唯一的中位數1:

$$P(X \leq 1) = P(X = 0) + P(X = 1) = \frac{3}{4} \geq \frac{1}{2},$$

$$P(X \geq 1) = P(X = 1) + P(X = 2) = \frac{3}{4} \geq \frac{1}{2}.$$

故1為一中位數。又任一 $-a < 1$,

$$P(X \leq a) \leq P(X = 0) = \frac{1}{4} < \frac{1}{2},$$

任一 $-a > 1$,

$$P(X \geq a) \leq P(X = 2) = \frac{1}{4} < \frac{1}{2},$$

皆非中位數。

另外，可看出 X 之眾數亦為1。

例24. 設 X 為一離散型的隨機變數，且 $P(X = 0) = 0.1$, $P(X = 1) = 0.4$, $P(X = 2) = 0.4$, $P(X = 3) = 0.1$ 。則任一 $-a \in [1, 2]$ 皆為中位數，而1, 2皆為眾數。

例25. 設隨機變數 X 之分佈函數為 $F(x) = x^2, 0 \leq x < 1$ 。令 $x^2 = 1/2$ ，解出 $x = \sqrt{2}/2 \doteq 0.707$ 。即 X 之中位數為 $\sqrt{2}/2$ 。也可以說 F 之中位數為 $\sqrt{2}/2$ 。若取 X 之機率密度函數為 $f(x) = 2x, 0 \leq x \leq 1$ ，則 X 之眾數為1。若取 X 之機率密度函數為 $f(x) = 2x, 0 \leq x < 1$ ，則眾數不存在。

我們常要藉助統計做各種決策。投資某項事業，可能成功而獲利若干，可能失敗而損失若干。那到底要不要投資呢？不能只看到成功機率很

大(說不定獲利很小), 也不能只看到獲利很大(說不定成功機率很低), 算一算淨所得之期望值, 是一簡單的決策依據。我們平常在判斷出門要不要帶雨傘, 也是先盤算一下期望損失(先估計下雨的機率, 及下雨不帶傘的損失等)。期望值在做決策時, 常扮演重要的角色。

例26. 某賭局的賭法如下: 投擲一公正的銅板, 若第 n 次投擲才首度出現正面, 則賭徒可獲得 a^n 元, 其中 $0 < a \leq 2$, 為一定值。試依期望所得, 決定賭徒每次賭之前, 該付多少元, 此賭局才是公正。在此公正賭局, 乃照一般的認知, 指所付的錢等於期望所得, 即讓期望淨所得為0。

解. 不難看出第 n 次投擲才首度出現正面之機率為 2^{-n} , $n \geq 1$ 。令 X 表賭徒賭1次之所得。先設 $0 < a < 2$, 則

$$E(X) = \sum_{n=1}^{\infty} a^n \cdot 2^{-n} = \sum_{n=1}^{\infty} \left(\frac{a}{2}\right)^n = \frac{a/2}{1-a/2} = \frac{a}{2-a}.$$

至於若 $a = 2$, 則

$$E(X) = \sum_{n=1}^{\infty} 2^n \cdot 2^{-n} = \sum_{n=1}^{\infty} 1 = \infty.$$

例如, 當 $a = 1.999$ 時, $E(X) = 1,999$, 即每次賭之前要付1,999元。一般可能會認為每次賭能得到 1.999^n 元, 與得到 2^n 元, 無太大差異。的確, 例如, $n = 10$ 時, $1.999^n \doteq 1,018.89$, 而 $2^{10} = 1,024$, 差異不大。但對前者, 每次賭只要付1,999元, 對後者, 則要付 ∞ 的錢。但有誰願意付(而且也沒有) ∞ 的錢去玩一賭局呢? 再仔細觀察。對 $a = 2$, 易知

$$P(\text{所得} \geq 2^n) = 2^{-n+1}, \text{ 且 } P(\text{所得} \leq 2^{n-1}) = 1 - 2^{-n+1}, n \geq 1.$$

例如, 當 $n = 11$, 有機率 $1 - 2^{-10} \doteq 0.999$, 所得不超過1,024元。又當 $n = 21$, 所得不超過 $2^{20} = 1,048,576$ (約百萬元)之機率, 約為0.999999, 已夠接近1了。要得到百萬元以上, 可說極不容易。但卻要先付 ∞ 的錢, 才能玩一次。但這可稱公正賭局呢! 這就是著名的彼得堡詭論(Petersburg paradox, Daniel Bernoulli, 1700-1782, 所提出)。當 $a = 2$ 時, 如何設計出

一較合理的付費方式，來參與此賭局，可參考黃文璋(2010)pp.295-297。

不論期望值是多好的一個隨機變數之代表值，難免會偏離該隨機變數，如何量測偏差究竟有多大呢？這就是變異數與標準差的功能。

設有一隨機變數 X ，且設期望值 $E(X)$ 存在。則 X 與 $E(X)$ 之離差為 $X - E(X)$ 。此值有正有負，但期望值 $E(X - E(X)) = E(X) - E(X) = 0$ 。離差之期望值為0，此亦為期望值之一性質。但我們往往是對離差之絕對值較感興趣。此正如射飛鏢時，有時上偏有時下偏，總不能得意地說平均命中紅心。

以 $|X - E(X)|$ 表離差之絕對值，此量仍為一隨機變數，如何衡量其大小呢？取期望值為一辦法。也就是求量測離差之絕對值的“平均”。但如果你微積分學得還不錯的話，應知道有關絕對值函數之求和或積分，往往有些麻煩(想想求 $\int_{-3}^3 |\sin x - 0.3x| dx$ 的例子)。對於 $E(|X - E(X)|)$ ，要討論何時 $X \geq E(X)$ ，何時 $X < E(X)$ ，這些不等式不見得好解。因此通常的作法，是考慮離差平方之期望值，而這就是變異數。由於是平方的期望值，像是距離的平方。因此若將變異數開平方，就像使其回到距離，標準差便產生了。

例27. 假設有 A, B 二項投資。投資 A 於一年後，有 $1/2$ 的機率賺一倍的錢，有 $1/4$ 的機率賠一半的錢，有 $1/4$ 的機率不賺不賠。投資 B 一年後，有 $3/4$ 的機率賺一半的錢，有 $1/4$ 的機率不賺不賠。若放 $10,000$ 元於投資 A ，則一年後之獲利 X ，為一離散型的隨機變數，機率密度函數為(略去“元”，底下同)

$$f_X(x) = \begin{cases} 1/2, & x = 10,000, \\ 1/4, & x = -5,000, \\ 1/4, & x = 0. \end{cases}$$

若放 $10,000$ 於投資 B ，則一年後之獲利 Y ，亦為一離散型的隨機變數，機率密度函數為

$$f_Y(y) = \begin{cases} 3/4, & y = 5,000, \\ 1/4, & y = 0. \end{cases}$$

依上述條件，可得

$$E(X) = \sum_x xf_X(x) = \frac{1}{2} \cdot 10,000 + \frac{1}{4} \cdot (-5,000) + \frac{1}{4} \cdot 0 = 3,750 .$$

$$E(Y) = \sum_y yf_Y(y) = \frac{3}{4} \cdot 5,000 + \frac{1}{4} \cdot 0 = 3,750 .$$

即投資A與投資B獲利之期望值相同。雖然有相同的期望值，但X之分佈較Y之分佈，散佈的較開，所以我們猜測X之變異數較大。底下來驗證此猜測。

$$\begin{aligned}\text{Var}(X) &= \sum_x (x - 3,750)^2 f_X(x) \\ &= \frac{1}{2}(10,000 - 3,750)^2 + \frac{1}{4}(-5,000 - 3,750)^2 + \frac{1}{4}(0 - 3,750)^2 \\ &= 42,187,500 .\end{aligned}$$

$$\begin{aligned}\text{Var}(Y) &= \sum_y (y - 3,750)^2 f_Y(y) \\ &= \frac{3}{4}(5,000 - 3,750)^2 + \frac{1}{4}(0 - 3,750)^2 \\ &= 4,687,500 .\end{aligned}$$

由於 $\text{Var}(X) > \text{Var}(Y)$ ，表示投資A之變異較大。若喜愛冒險者，說不定會採投資A，有時會有較高獲利。個性保守者，可能會採投資B，穩紮穩打。

例28. 某項食品是以機械填裝，每包標示16公斤。若容量不足，顧客可能會抱怨，若容量過多，公司也有損失。令X表每包之容量。假設X有 $U[15.8, 16.2]$ 分佈，即機率密度函數為 $f(x) = 2.5$, $15.8 \leq x \leq 16.2$ 。則

$$E(X) = \int_{-\infty}^{\infty} xf(x)dx = \int_{15.8}^{16.2} 2.5xdx = 16.0 .$$

所以平均而言，機器填裝的容量是正確的。但

$$P(X < 16) = P(X > 16) = 0.5,$$

即各有0.5的機率，會容量不足及容量超過。我們來求其變異數。

$$\text{Var}(X) = \int_{-\infty}^{\infty} (x - 16)^2 f(x) dx = \int_{15.8}^{16.2} 2.5(x - 16)^2 dx = 0.0133.$$

標準差為 $\sqrt{\text{Var}(X)} \doteq 0.115$ 。

為了降低變異，公司引進新機器，新的容量 Y 之機率密度函數為

$$g(y) = \begin{cases} 25(y - 16) + 5, & 15.8 \leq y < 16, \\ 25(16 - y) + 5, & 16 \leq y < 16.2. \end{cases}$$

則仍有 $E(Y) = 16$ ，但 $\text{Var}(Y) = 1/150 \doteq 0.006$ ，標準差 $\doteq 0.0816$ 。變異數下降一半以上，標準差則下降約29%。

圖5給出 X 及 Y 機率密度函數之圖形。由圖形亦可看出 Y 之變異數較 X 之變異數小：較多的機率配置在 Y 之期望值的近傍。

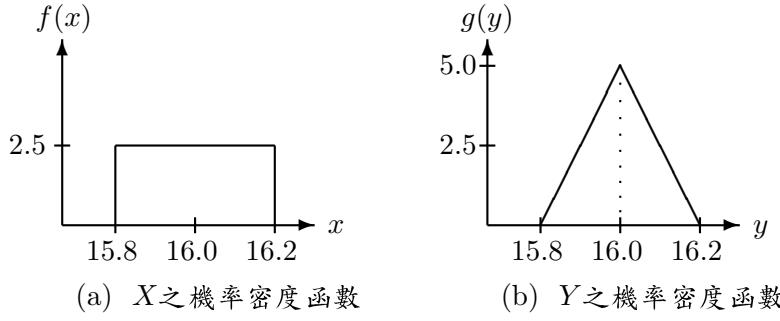


圖5 例28中 X 及 Y 機率密度函數之圖形

我們先給變異數之某些性質。

定理4.8 設 X 為一隨機變數，則下述二式成立，其中 a, b 為常數。

$$(21) \quad \text{Var}(aX + b) = a^2\text{Var}(X),$$

$$(22) \quad \text{Var}(X) = E(X^2) - (E(X))^2.$$

由於變異數一定不是負的（非負隨機變數 $(X - E(X))^2$ 之期望值必為非負，見定理6之(ii))，故由(22)式得

$$(23) \quad E(X^2) \geq (E(X))^2.$$

又由(21)式可看出(取 $a = 0$)常數的變異數為0。這點由(22)式亦可看出。即若存在一常數 b , 使得 $P(X = b) = 1$, 則因 $E(X^2) = b^2$, $E(X) = b$, 故 $\text{Var}(X) = 0$ 。這當然是合理的。既然是常數(可視為一退化的隨機變數), 就沒有變異, 每次觀測皆得到該常數。反之, 若 $\text{Var}(X) = 0$, 則存在常數 b , 使得 $P(X = b) = 1$ 。

例29. 投擲一公正的骰子, 令 X 表所得之點數。試求 X 之變異數及標準差。

解.前面已求出 $E(X) = 3.5 = 7/2$ 。又 $E(X^2) = \sum_{i=1}^6 i^2/6 = 91/6$ 。故

$$\text{Var}(X) = E(X^2) - (E(X))^2 = \frac{91}{6} - \frac{49}{4} = \frac{35}{12},$$

且 X 之標準差為 $\sqrt{35/12} \doteq 1.7078$ 。

例30. 常態分佈(normal distribution)為一極重要的分佈。設 X 有參數 μ 及 σ^2 之常態分佈, 以 $\mathcal{N}(\mu, \sigma^2)$ 表之, 其中 $\mu \in R$, $\sigma^2 > 0$ 。則 X 之機率密度函數為

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/2\sigma^2}, -\infty < x < \infty.$$

當 $\mu = 0, \sigma = 1$, 即得**標準常態分佈**(standard normal distribution), 以 $\mathcal{N}(0, 1)$ 表之, 其機率密度函數為

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, -\infty < x < \infty.$$

常態分佈有很多好的性質, 其中之一是當 X 有 $\mathcal{N}(\mu, \sigma^2)$ 分佈, 則 $(X - \mu)/\sigma$ 有 $\mathcal{N}(0, 1)$ 分佈。因此

$$P(X \leq x) = P\left(\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}\right) = P(Z \leq \frac{x - \mu}{\sigma}),$$

其中, Z 有 $\mathcal{N}(0, 1)$ 分佈。即對任一常態分佈, 其機率值皆可經由 $\mathcal{N}(0, 1)$ 分佈之機率值得到。這是其他分佈少有的性質。而由 X 至 $(X - \mu)/\sigma$ 之變換, 便稱為**標準化**(standardized)。對於 $\mathcal{N}(\mu, \sigma^2)$ 分佈, 可求出

$$E(X) = \mu, \text{Var}(X) = \sigma^2,$$

即二參數分別為其期望值及標準差。由標準常態分佈的機率值表，可得當 X 有 $\mathcal{N}(\mu, \sigma^2)$ 分佈，

$$P(|X - \mu| \leq \sigma) = P(|Z| \leq 1) = 0.6826,$$

$$P(|X - \mu| \leq 2\sigma) = P(|Z| \leq 2) = 0.9545,$$

$$P(|X - \mu| \leq 3\sigma) = P(|Z| \leq 3) = 0.9974.$$

即 X 與期望值差異不超過1標準差，2標準差，3標準差之機率，分別約為0.6826, 0.9545及0.9974(其他分佈當然不會也是這3個值)。對一常態分佈，觀測值會偏離期望值3個標準差之機率，僅約為0.003。

對一隨機變數，於給出一次及二次動差(變異數是基於二次動差)後，對其分佈便有了基本的了解。若知道更多次的動差，對其分佈就愈了解。所謂分佈，顧名思義，就是一隨機變數取值之散佈情況。由於散佈著，我們才又想以一些基本的量來描述散佈的情況。這就是動差的功能。

大家看，我們由常數推廣至隨機變數，由於隨機的難以掌握，又想以一些簡單的量來描述此隨機的量。數學上就是如此常在由簡入繁，又由繁入簡。

另外，亦可以一些轉換，來描述隨機變數的分佈。如母函數(generating function, 或稱生成函數)，拉普拉斯轉換(Laplace transform)，特徵函數(characteristic function)及動差母函數(moment generating function)等，乃幾個常見可以唯一決定隨機變數之分佈的轉換。細節在此不再討論。

5 多維隨機變數

如同函數可以有多個變數，我們也可以有多維(或說多變數，多變量)隨機變數。聯合機率密度函數，聯合分佈函數也就對應產生。例如，二隨機變數 X, Y 之聯合分佈函數 $F(x, y) = P(X \leq x, Y \leq y)$ 。統計分析要先收集資料，而很多資料有不只一個變數，多變數的討論，為統計學中重要的

題材。本文只是對隨機變數給一初步的介紹，因此不多著墨之。我們只給幾個概念。

定義2. 設二隨機變數 X, Y , 以 $f(x, y)$ 為聯合機率密度函數, X, Y 之機率密度函數分別以 $f_X(x)$ 及 $f_Y(y)$ 表之。若

$$(24) \quad f(x, y) = f_X(x)f_Y(y), \quad x, y \in R,$$

則稱 X 與 Y 相互獨立(mutually independent), 或獨立。

定理5.9 設二隨機變數 X, Y , 以 $F(x, y)$ 為聯合分佈函數, X, Y 之分佈函數分別為 $F_X(x)$ 及 $F_Y(y)$ 。則 X 與 Y 獨立, 若且唯若

$$(25) \quad F(x, y) = F_X(x)F_Y(y), \quad x, y \in R;$$

若且唯若存在函數 $G(x)$ 及 $H(y)$, 使得對 $\forall x, y \in R$,

$$(26) \quad F(x, y) = G(x)H(y).$$

二隨機變數獨立, 表知道其中之一的值, 對另一變數的分佈, 沒有影響。在某些特殊的情況, 有可能一隨機變數為另一隨機變數之函數, 兩者可說關係極度密切, 但卻相互獨立。

同理我們也可以定義 n 個隨機變數之獨立。另外, 二隨機變數若不獨立, 如何來表示兩者之關係, 或說互相變化之情況, 也是統計裡常討論的題材。

n 個隨機變數 X_1, \dots, X_n , 若相互獨立, 且有共同的分佈(independent and identically distributed, 簡稱iid), 便稱此為一組隨機樣本(random sample)。在統計分析裡常會接觸隨機樣本, 很多統計的理論都基於隨機樣本。

定理2指出, 對一滿足分佈函數那些性質的函數, 能給一機率空間, 並在其上定義一隨機變數, 以該函數為其分佈函數。現若有二分佈函數 F_1 及 F_2 , 則可否給出一機率空間 $(\Omega, \mathcal{F}, \mathcal{P})$, 且在 Ω 上定義二隨機變

數 X 與 Y , 使得 X 與 Y 獨立, 且各以 F_1 及 F_2 為分佈函數? 答案是肯定的, 不過其證明在此略去。

6 再論隨機性

本章介紹隨機變數, 不只在機率與統計裡, 在日常生活中, 人們也常提到“隨機”一詞, 其涵義究竟為何。

如果是說隨機變數, 則就是指非常數, 遵循某一分佈。另外, 可能會有下述幾個常見約定俗成的定義。

第一種是指隨機樣本。譬如說有一隨機變數 X , 重複地觀測 n 次, 得到 X_1, \dots, X_n 。則 X_1, \dots, X_n 為 iid, 為一組隨機樣本。這種例子很多。欲估計一銅板出現正面的機率 p , 投擲 n 次, 假設各次間相互獨立, n 次投擲得到 X_1, \dots, X_n , 其中 $X_i = 1$, 表示第 i 次投擲出現正面, $X_i = 0$, 則表示出現反面, 且 $P(X_i = 1) = p$, $P(X_i = 0) = 1 - p$, 則 X_1, \dots, X_n 為一組隨機樣本。又如欲估計某廠牌燈泡壽命, 假設燈泡品質皆相同, 取 n 個測試, 分別得到使用時間 X_1, \dots, X_n , 則可合理地假設 X_1, \dots, X_n 為 iid, 因此為一組隨機樣本。

第二種情況是指隨機取樣, 則便有均勻分佈的意思。我們分連續型及離散型來說明。譬如說自區間 $[a, b]$ 隨機地取一點, $a < b$ 。若取中的點以 X 表之, 則乃表 X 在 $[a, b]$ 有均勻分佈。因此 X 落於 $[a, b]$ 之任一子區間的機率, 等於此子區間之長度除以區間長度 $b - a$ 。如果是自區間 $[a, b]$ 隨機地取 n 個點, 取中的點以 X_1, \dots, X_n 表之, 則便表 X_1, \dots, X_n 為 iid, 皆在 $[a, b]$ 均勻分佈。其次看離散的情況。所謂自 1 至 10, 隨機地取 1 數, 乃指 1 至 10, 每一數被取中的機率皆相等, 都是 $1/10$ 。又如樂透彩開獎, 想檢驗號碼是否隨機產生。假設是 42 取 6 的樂透彩, 共有 $\binom{42}{6} = 5,245,786$ 種號碼的組合。就是要檢驗是否每一組合出現之機率皆為 $1/5,245,786$ (而非只是檢驗 1 至 42 的號碼, 是否出現的機率皆為 $1/42$)。

不過有些情況下, 隨機取樣, 其中的“隨機”一詞意義可能並不很明確。見下例。

例31. 假設平面上有一圓，半徑為 r 。在圓上隨機畫一條弦，我們想求此弦長度大於圓之一內接等邊三角形邊長 a 的機率。令 A 表一隨機的弦其長度會大於 a 的事件。而一隨機的弦其長度可由下述三者之一決定：此弦與圓心之距離 D ；此弦的中點位置 M ；此弦與圓心所張開的角 θ 。底下分別假設 D, M, θ 在其取值範圍內均勻分佈，而求出 A 之機率。

(1) 設 D 在 $[0, r]$ 均勻分佈。此假設是基於若有一隻尺，自與圓相切處以等速平行地向圓心移動，隨時停止便與圓交出一條弦。由幾何性質知，事件 A 發生，若且唯若 $D < r/2$ ，故 $P(A) = 1/2$ 。

(2) 設 M 在整個圓內均勻分佈。此假設是基於由圓內任意取一點 M ，當做弦的中點，自 M 做垂直此點與圓心的連線便得到一弦。易見此弦長度是否大於 a ，就看 M 是否落在半徑為 $r/2$ 之同心圓內。故 $P(A) = P(M\text{落在小圓內}) = \text{小圓面積}/\text{大圓面積} = 1/4$ 。

(3) 設 θ 在 $[0, 2\pi]$ 均勻分佈。此假設是基於自圓周上任取一點當做弦的一個端點，然後自此點沿著圓周順時針等速移動，隨時停止便得到弦的另一端點。易見事件 A 發生，若且唯若此弦二端點與圓心所張開之角 θ ，介於 $2\pi/3$ 與 $4\pi/3$ 之間，故 $P(A) = (4\pi/3 - 2\pi/3)/2\pi = 1/3$ 。

故在不同的假設下，本問題的答案可以是 $1/2, 1/4$ ，或 $1/3$ 。甚至在另外的假設下，有可能得到其他答案。此問題即為伯特朗詭論(Bertrand paradox)。顯見在本例中，所謂“隨機”畫一條弦，其中隨機的意義，顯然不若之前自區間 $[a, b]$ 隨機取點那麼明確。若對隨機的解釋不同，便可能得到不同的答案。

再看一有趣的例子。

例32. 假設有一無限大的袋子，另有無限多個的球，編號依序為 $1, 2, 3, \dots$ 。現進行下述實驗：自某時刻起(時間 0)，將1號至10號球放進袋中，然後取出10號球。假設放球及取球所花時間都可忽略。 $1/2$ 分鐘後，將11號至20號球放進袋中，然後取出20號球。又 $1/4$ 分鐘後，將21號至30號球放進袋中，然後取出30號球。再來是又 $1/8$ 分鐘後， \dots ，餘此類推。我們有興趣

的問題是，1分鐘後，袋中有多少球。

此問題的答案很明顯，就是袋中有無限多個球。因凡編號不是 $10n$ 的球， $n \geq 1$ ，皆在袋中。

現將情況改變。自時間0開始，將1號至10號球放進袋中，然後取出1號球。 $1/2$ 分鐘後，將11號至20號球放進袋中，然後取出2號球。再 $1/4$ 分鐘後，將21號至30號球放進袋中，然後取出3號球。再來是又 $1/8$ 分鐘後，…，餘此類推。則1分鐘後，袋中有多少球。

令人驚訝的是，對此情況，答案是袋中空無一球。怎麼可能？每次不仍是放10球取1球，何以第一情況1分鐘後，袋中有無限多個球，而在第二情況，1分鐘後袋中卻一球皆無？你實在無法相信。說明如下。在第二情況，1號球是一開始(時間0)便被取走。至於 n 號球， $n \geq 2$ ，在 $(1/2)^1 + (1/2)^2 + \dots + (1/2)^{n-1} (= 1 - (1/2)^{n-1})$ 分鐘後被取走。故對 $\forall n \geq 1$ ， n 號球在1分鐘後，皆不在袋中。即得證1分鐘後，袋中空無一球。

因此，雖然同樣每次放10球，取1球，但那1個球如何取，造成的結果差異很大。在第一情況，只有編號為 $10n$ 的球才被取出， $n \geq 1$ 。但在第二情況，每一號球，最終都被取出。

我們再考慮第三情況。放球的方式不變，但取球的方式改為每次自袋裡已有的球中，“隨機”取1球。例如，在時間0，放進1號至10號球，然後自此10個球中，隨機的取1球(即1至10號球，每號球被取中之機率皆為 $1/10$)。對此新情況，我們仍問，1分鐘後，袋中有多少個球。

解。我們將證明1分鐘後袋中空無一球的機率為1。先考慮1號球。令 E_n 表首 n 次取球後，1號球仍在袋中的事件。則

$$P(E_n) = \frac{9}{10} \cdot \frac{18}{19} \cdot \frac{27}{28} \cdots \frac{9n}{9n+1}.$$

上式如何得到？ n 次取球後，1號球仍要在袋中，表第1次只能從10個球中，1號之外，其餘的9個球取；第2次只能從19個球中，1號之外，其餘的18個球取，餘類推。例如，最後一次只能自 $9n+1 (= 10n - (n-1))$ 個球中，1號之外的 $9n$ 個球取。

1分鐘後，1號球仍在袋中的事件，即為 $\bigcap_{n=1}^{\infty} E_n$ 。由於 $E_1 \supset E_2 \supset \dots$

$\supset E_n \supset E_{n+1} \supset \dots$, 故利用機率函數的單調性質(見底下註1),

$$P(\text{1分鐘後, 1號球不在袋中}) = P\left(\bigcap_{n=1}^{\infty} E_n\right) = \lim_{n \downarrow \infty} P(E_n) = \prod_{n=1}^{\infty} \frac{9n}{9n+1}.$$

我們如下證明 $\prod_{n=1}^{\infty} (9n/(9n+1)) = 0$ 。首先因

$$\prod_{n=1}^{\infty} \frac{9n}{9n+1} = \left(\prod_{n=1}^{\infty} \left(1 + \frac{1}{9n}\right)\right)^{-1},$$

故若能證出 $\prod_{n=1}^{\infty} (1 + 1/(9n)) = \infty$ 即得證。現對 $\forall n \geq 1$,

$$\begin{aligned} \prod_{n=1}^{\infty} \left(1 + \frac{1}{9n}\right) &\geq \prod_{n=1}^m \left(1 + \frac{1}{9n}\right) = \left(1 + \frac{1}{9}\right)\left(1 + \frac{1}{18}\right) \cdots \left(1 + \frac{1}{9m}\right) \\ &> \frac{1}{9} + \frac{1}{18} + \cdots + \frac{1}{9m} = \frac{1}{9} \sum_{i=1}^m \frac{1}{i}. \end{aligned}$$

因當 $m \rightarrow \infty$ 時, $\sum_{i=1}^m 1/i \rightarrow \infty$, 故得 $\prod_{n=1}^{\infty} (1 + 1/(9n)) = \infty$ 。故若令 F_i 表*i*號球1分鐘後在袋中的事件, 則 $F_1 = \bigcap_{n=1}^{\infty} E_n$, 且 $P(F_1) = 0$ 。同理可證 $P(F_i) = 0, \forall i \geq 1$ 。而1分鐘後, 袋中不是空的之事件乃 $\bigcup_{i=1}^{\infty} F_i$ 。利用波爾不等式(Boole's inequality), 得

$$P\left(\bigcup_{i=1}^{\infty} F_i\right) \leq \sum_{i=1}^{\infty} P(F_i) = 0.$$

故1分鐘後, 袋中為空之機率的確是1。

註1. 事件 $\{E_n, n \geq 1\}$ 若滿足

$$E_1 \supset E_2 \supset \cdots \supset E_n \supset E_{n+1} \supset \cdots,$$

便稱漸減數列, 若滿足

$$E_1 \subset E_2 \subset \cdots \subset E_n \subset E_{n+1} \subset \cdots,$$

便稱漸增數列。對漸減或漸增數列的事件 $\{E_n, n \geq 1\}$, 皆有

$$\lim_{n \rightarrow \infty} P(E_n) = P\left(\lim_{n \rightarrow \infty} E_n\right).$$

此即機率函數之單調性質。

參考文獻

1. 黃文璋(2010). 機率論，第二版。華泰文化事業股份有限公司，台北市。