

1. אם X רציף:

$$\mathbb{E}(Y) = \int_{-\infty}^{\infty} h(x) f_X(x) dx$$

2. אם X בדיד (מקבל ערכים x_n בהסתברות p_n):

$$\mathbb{E}(Y) = \sum p_n h(x_n)$$

3. אם X מעורב, מפרקים את X למשתנה מקרי רציף X' ומשתנה מקרי בדיד X'' :

$$\mathbb{E}(Y) = p \sum p_n h(x_n) + (1-p) \int_{-\infty}^{\infty} h(x) f_X(x) dx$$

הוכחה: למקרה הבדיד: $h: \mathbb{R} \rightarrow \mathbb{R}$, ומכיוון ש- h איננה חח"ע, יש ל- h אחד מקורות רבים. נסמן את הערכים ש- Y מקבל ונסמן A_j את

$$A_j = \{n : h(x_n) = y_j\}$$

ונסמן ב- q_j את ההסתברות ש- $Y = y_j$.

$$q_j = P(Y = y_j) = P(X \in A_j) = \sum_{i \in A_j} p_i$$

נחשב את התוחלת של Y :

$$\mathbb{E}Y = \sum_j q_j y_j = \sum_j \sum_{n \in A_j} p_n h(x_n) = \sum_n p_n h(x_n)$$

למקרה הרציף: נוכיח למקרה ש- h מונוטונית ממש. נניח ש- h עולה ממש וגזירה.

$$\mathbb{E}Y = \int_{-\infty}^{\infty} y f_Y(y) dy = \int_{-\infty}^{\infty} y f_X(h^{-1}(y)) [h^{-1}(y)]' dy$$

$$dx = [h^{-1}(y)]' dy, y = h(x) \text{ נציב}$$

$$\mathbb{E}Y = \int_{-\infty}^{\infty} h(x) f_X(x) dx$$

■

הערה 8.4 אם X מעורב ו- $F_Z = (1-p)F_Z + pF_W$ כאשר W בדיד ו- Z רציף אז

$$\mathbb{E}X = p\mathbb{E}W + (1-p)\mathbb{E}Z$$

דוגמאות

1. $Y = X^2$ נורמלי סטנדרטי,

$$\mathbb{E}Y = \int_{-\infty}^{\infty} x^2 \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$$

2. $h(x) = |x|$, $Y = |X|$

$$\mathbb{E}Y = \int_{-\infty}^{\infty} |x| \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = 2 \int_0^{\infty} |x| \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$$

מטעמי סימטריה ניתן לעשות אינטגרל רק מצד אחד ולהכפיל ב-2

$$\mathbb{E}Y = \left[\frac{2}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \right]_0^{\infty} = \sqrt{\frac{2}{\pi}}$$

3. $h(t) = e^t$, $Y = e^X$

$$\begin{aligned} \mathbb{E}Y &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^x e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(x^2 - 2x + 1) + \frac{1}{2}} dx \\ &= \frac{\sqrt{e}}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(x-1)^2} dx = \sqrt{e} \end{aligned}$$

4. מקרה בדיד: זורקים קוביה הוגנת. אם יוצא $j \in \{1, \dots, 6\}$ משלמים x_j וז' דוגמה מהטיפוס שבו אנחנו מטפלים. נאמר ש- X מקבל את הערכים $\{1, \dots, 6\}$ בהסתברות $\frac{1}{6}$, והפונקציה h היא $h(j) = x_j$. התוחלת של המשתנה $Y = h(X)$ היא התוצאה הצפויה לתשלום.

8.5 תכונות התוחלת

1. אם X משתנה מקרי מנוון ($X \equiv c$) אז $\mathbb{E}X = c$

2. עבור a קבוע, $Y = aX$ אז $\mathbb{E}Y = a\mathbb{E}X$

3. עבור a קבוע, $\mathbb{E}(X + a) = \mathbb{E}X + a$

4. אם X משתנה מקרי ונתונות שתי פונקציות g, h אז $\mathbb{E}(g(X) + h(X)) = \mathbb{E}g(X) + \mathbb{E}h(X)$. הוכחה למקרה ש- X רציף:

$$\begin{aligned} \mathbb{E}(g(X) + h(X)) &= \int_{-\infty}^{\infty} (g(x) + h(x)) f_X(x) dx = \\ &= \int_{-\infty}^{\infty} g(x) f_X(x) dx + \int_{-\infty}^{\infty} h(x) f_X(x) dx \\ &= \mathbb{E}g(X) + \mathbb{E}h(X) \end{aligned}$$

5. לכל X, Y : $\mathbb{E}(X + Y) = \mathbb{E}X + \mathbb{E}Y$ (4) הוא מקרה פרטי של תכונה זו) (בתנאי של- X ו- Y יש בכלל תוחלת).

$$6. \mathbb{E}X \geq 0 \Leftrightarrow X \geq 0$$

7. מסקנה מ-5 ו-6: אם $X \geq Y$ אז גם $\mathbb{E}X \geq \mathbb{E}Y$

מסקנה 8.5 התוחלת היא אופרציה ליניארית

8.6 המומנט של משתנה מקרי

הגדרה 8.6 יהי X מ"מ ו- $1 \leq k$ שלם, אז המומנט ה- k של X הוא

$$m_k = M_k = \mathbb{E}X^k$$

דוגמאות

1. נניח $X \sim \text{Pois}(\lambda)$ ונחשב את M_2 .

$$\begin{aligned} \mathbb{E}X^2 &= \sum x_n^2 p_n = \sum_{n=0}^{\infty} n^2 e^{-\lambda} \frac{\lambda^n}{n!} = e^{-\lambda} \sum_{n=0}^{\infty} \left(n(n-1) \frac{\lambda^n}{n!} + n \frac{\lambda^n}{n!} \right) \\ &= e^{-\lambda} \sum_{n=0}^{\infty} n(n-1) \frac{\lambda^n}{n!} + e^{-\lambda} \sum_{n=0}^{\infty} n \frac{\lambda^n}{n!} = e^{-\lambda} \lambda^2 \left(\sum_{n=0}^{\infty} \frac{\lambda^n}{n!} \right)' + e^{-\lambda} \lambda \left(\sum_{n=0}^{\infty} \frac{\lambda^n}{n!} \right)' \\ &= \lambda^2 + \lambda \end{aligned}$$

2. $X \sim N(0, 1)$. נחשב את M_k :

$$\begin{aligned} M_k &= \mathbb{E}X^k = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^k e^{-\frac{x^2}{2}} dx \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^{k-1} x e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^{k-1} \left(-e^{-\frac{x^2}{2}} \right)' dx \\ &= \frac{1}{\sqrt{2\pi}} \left[\left(-x^{k-1} e^{-\frac{x^2}{2}} \right)_{-\infty}^{\infty} + \int_{-\infty}^{\infty} (k-1) x^{k-2} e^{-\frac{x^2}{2}} dx \right] \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} (k-1) x^{k-2} e^{-\frac{x^2}{2}} dx = \frac{(k-1)}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^{k-2} e^{-\frac{x^2}{2}} dx \\ &= (k-1) M_{k-2} = (k-1) \mathbb{E}X^{k-2} \end{aligned}$$

אם $k = 2l$ זוגי אז

$$\mathbb{E}X^k = (2l-1)(2l-3)\cdots 1 = (2l-1)!!$$

ואם k אי זוגי המומנט הוא אפס.

8.7 שונות

אנחנו מחפשים מדד מספרי למידת הפיזור של X סביב התוחלת שלו. $\mathbb{E}(X - \mu) = 0$ ולכן לא יתאים למטרה. יותר הגיוני למדוד $\mathbb{E}|X - \mu|$ אבל קשה לחשב אותו. מסיבות טכניות ואחרות מסתכלים על

$$\mathbb{E}(X - \mu)^2$$

נוסחה זו נותנת משקל גדול יותר לשגיאות גדולות מאשר לשגיאות קטנות.

הגדרה 8.7 יהי X מ"מ עם תוחלת $\mathbb{E}X = \mu$. אז השונות (Variance) של X היא

$$\text{Var}(x) = \sigma_X^2 = \sigma^2 = \mathbb{E}(X - \mu)^2$$

סטיית התקן מסומנת σ .

8.7.1 תכונות השונות

נחשב את השונות סביב נקודה כלשהי, לאו דווקא התוחלת של X :

$$\begin{aligned} \mathbb{E}(X - a)^2 &= \mathbb{E}((X - \mu) + (\mu - a))^2 = \\ &= \mathbb{E}(X - \mu)^2 + \underbrace{2\mathbb{E}(\mu - a)(X - \mu)}_0 + \mathbb{E}(\mu - a)^2 \\ &= \mathbb{E}(X - \mu)^2 + (\mu - a)^2 \end{aligned}$$

מסקנות:

1. $\mathbb{E}(X - a)^2 \geq \mathbb{E}(X - \mu)^2$, ושוויון מתקיים רק אם $a = \mu$. יוצא שאם נמדוד את הסטיות מכל נקודה a , אז הסטייה המינימלית תתקבל ב- $a = \mu$.

2. נציב $a = 0$:

$$\mathbb{E}X^2 = \mathbb{E}(X - \mu)^2 + \mu^2 = \text{Var}(X) + (\mathbb{E}X)^2$$

כלומר

$$\text{Var}(X) = \mathbb{E}X^2 - (\mathbb{E}X)^2$$

השונות שווה למומנט השני פחות התוחלת בריבוע.

3. השונות היא תוחלת של משתנה אי שלילי, ולכן היא אי שלילית. $\text{Var}(X) \geq 0$.

$$\begin{aligned} \mathbb{E}X^2 - (\mathbb{E}X)^2 &\geq 0 \\ \mathbb{E}X^2 &\geq (\mathbb{E}X)^2 \end{aligned}$$

כל X עבורו קיימים מומנט שני ותוחלת. למעשה אם נחליף את X ב- $|X|$ אז נקבל

$$\mathbb{E}|X| \leq \sqrt{\mathbb{E}X^2}$$

ואם ל- X יש מומנט שני אז יש לו גם תוחלת (התוחלת של X מתכנסת בהחלט).

4. נניח $X \equiv c$ משתנה מקרי מנוון, $\text{Var}(X) = 0$.

5. לכל a קבוע,

$$\text{Var}(X + a) = \text{Var}(X)$$

כי

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

6. אם a קבוע אז

$$\text{Var}(aX) = a^2 \text{Var}(X)$$

$$\sigma_{aX} = |a| \sigma_X$$

דוגמאות

1. $X \sim \text{Pois}(\lambda)$

$$\text{Var}(X) = \mathbb{E}X^2 - (\mathbb{E}X)^2 = \lambda^2 + \lambda - \lambda^2 = \lambda$$

2. $X \sim \text{Bin}(n, p)$

$$\mathbb{E}X = np$$

נחשב את המומנט השני של X :

$$\begin{aligned} \mathbb{E}X^2 &= \sum_{j=0}^n j^2 \binom{n}{j} p^j q^{n-j} = p^2 \sum_{j=0}^n j(j-1) \binom{n}{j} p^{j-2} q^{n-j} + p \sum_{j=0}^n j \binom{n}{j} p^{j-1} q^{n-j} \\ &= p^2 \left(\sum_{j=0}^n \binom{n}{j} p^j q^{n-j} \right)'' + p \left(\sum_{j=0}^n \binom{n}{j} p^j q^{n-j} \right)' \\ &= p^2 [(p+q)^n]'' + p [(p+q)^n]' = p^2 n(n-1) + pn \end{aligned}$$

ולכן השונות של X היא

$$\begin{aligned} \text{Var}(X) &= \mathbb{E}X^2 - (\mathbb{E}X)^2 = p^2 n(n-1) + pn - (pn)^2 \\ &= p^2 n^2 - p^2 n + pn - p^2 n^2 = pn(1-p) = npq \end{aligned}$$

$$\mathbb{E}X = \frac{1}{p}, X = \text{Geom}(p) \quad .3$$

$$\begin{aligned} \mathbb{E}X(X-1) &= \sum_k k(k-1)pq^{k-1} \\ &= pq \sum_k k(k-1)pq^{k-2} = pq \left(\sum_k q^k \right)'' \\ &= pq \left(\frac{1}{1-q} \right)'' = pq \left(\frac{2}{(1-q)^3} \right) = \frac{2pq}{p^3} = \frac{2q}{p^2} \end{aligned}$$

לכן

$$\begin{aligned} \text{Var}(X) &= \mathbb{E}X^2 - (\mathbb{E}X)^2 = \mathbb{E}X(X-1) + \mathbb{E}X - (\mathbb{E}X)^2 \\ &= \frac{2q}{p^2} + \frac{1}{p} - \frac{1}{p^2} = \frac{2q+p-1}{p^2} = \frac{q}{p^2} \end{aligned}$$

$$,X \sim U(0,1) \quad .4$$

$$\mathbb{E}X^2 = \int_0^1 x^2 \cdot 1 dx = \frac{1}{3}$$

$$\text{Var}(X) = \frac{1}{3} - \left(\frac{1}{2} \right)^2 = \frac{1}{12}$$

$$\boxtimes X \sim U(a,b) \boxtimes$$

$$\text{Var}(X) = \text{Var}(X-a) = (b-a)^2 \text{Var}\left(\frac{X-a}{b-a}\right) = \frac{(b-a)^2}{12}$$

$$\mathbb{E}X = \frac{1}{\lambda}, X \sim \exp(\lambda) \quad .5$$

$$\mathbb{E}X^2 = \int_0^\infty x^2 \lambda e^{-\lambda x} dx = \frac{2}{\lambda^2}$$

$$\text{Var}(X) = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}$$

$$\mathbb{E}X^2 = 1, \mathbb{E}X = 0, X \sim N(0,1) \quad .6$$

$$\text{Var}(X) = 1 - 0^2 = 1$$

$$:X \sim N(\mu, \sigma^2) \boxtimes$$

$$\frac{X-\mu}{\sigma} \sim N(0,1)$$

או אם $Z \sim N(0, 1)$ אז

$$X = \sigma Z + \mu$$

לכן

$$\begin{aligned} \mathbb{E}X &= \mu \\ \text{Var}(X) &= \sigma^2 \text{Var}(Z) = \sigma^2 \end{aligned}$$

ניתן היה גם לחשב את השונות ישירות:

$$\text{Var}(X) = \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{\infty} (x - \mu)^2 e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx$$

8.7.2 הקשר בין המומנט השני לטורי פוריה

נניח ש- $X \sim U(0, 2\pi)$, $f_X(x) = \frac{1}{2\pi}$, $0 \leq x \leq 2\pi$, ונתונה $h(t)$ אז,

$$\begin{aligned} \mathbb{E}h(X) &= \frac{1}{2\pi} \int_0^{2\pi} h(x) dx \\ \mathbb{E}X^2 &= \frac{1}{2\pi} \int_0^{2\pi} x^2 dx \\ \mathbb{E}h^2(X) &= \frac{1}{2\pi} \int_0^{2\pi} h^2(x) dx = \|h\|_{L^2(0,2\pi)}^2 \end{aligned}$$

באופן כללי אם X משתני מקרי עם צפיפות אז

$$\mathbb{E}h^2(X) = \int_{-\infty}^{\infty} h^2(x) dx$$

8.8 אי שיוויון צ'בישב

אינטואיטיבית, אם נבחר X רחוק מהמוצע, סביר שההסתברות לכך תהיה קטנה יותר מאשר X קרוב למוצע.

משפט 8.8 יהי X מ"מ עם תוחלת μ ושונות σ^2 , אז לכל מספר חיובי מתקיים

$$P(|X - \mu| > b) < \frac{\sigma^2}{b^2}$$

מכונה אמורה ליצר מוטות באורך מטר. בפועל המוטות הם בעלי אורך מקרי X . $\sigma_X = \frac{1}{1000}$. ידוע לנו גם כי $\sigma_X = \frac{1}{1000}$. מהי ההסתברות שהסטיה גדולה מסנטימטר?

$$P\left(|X - 1| > \frac{1}{100}\right)$$

אי שיויון נותן הערכה בלבד:

$$P\left(|X - 1| > \frac{1}{100}\right) < \frac{\left(\frac{1}{1000}\right)^2}{\left(\frac{1}{100}\right)^2} = \frac{1}{100}$$

הוכחה: נניח ש- X מ"מ רציף עם צפיפות $f_X(x)$.

$$\begin{aligned} P(|X - \mu| > b) &= \int_{\{|X - \mu| > b\}} f_X(x) dx \\ &\leq \int_{\{|X - \mu| > b\}} \frac{(x - \mu)^2}{b^2} f_X(x) dx \end{aligned}$$

מכיוון ש- $\frac{x-\mu}{b}$ גדול מאחד בתחום. נגדיל את התחום לכל הישר, וכך נגדיל עוד יותר את האינטגרל:

$$P(|X - \mu| > b) \leq \frac{1}{b^2} \int_{-\infty}^{\infty} (x - \mu)^2 f_X(x) dx$$

עבור $h(x) = (x - \mathbb{E}X)^2$ קיבלנו בעצם את התוחלת של המשתנה המקרי $\mathbb{E}h(X)$:

$$P(|X - \mu| > b) \leq \frac{1}{b^2} \mathbb{E}(X - \mathbb{E}X)^2 = \frac{\sigma^2}{b^2}$$

■

במשתנים מקריים ספציפים אפשר לקבל קצב שאיפה לאפס (כאשר $b \rightarrow \infty$) מהיר בהרבה.
נניח ש- $X \sim N(0, 1)$:

$$\begin{aligned} P(|X - \mu| > b) &= P(|X| > b) \\ &= \frac{2}{\sqrt{2\pi}} \int_0^{\infty} e^{-\frac{x^2}{2}} dx < \frac{2}{\sqrt{2\pi}} \int_0^{\infty} \frac{e^x}{e^b} e^{-\frac{x^2}{2}} dx \end{aligned}$$

כי $\frac{x}{b} > 1$.

$$P(|X| > b) \leq e^{-b} \underbrace{\frac{2}{\sqrt{2\pi}} \int_0^{\infty} e^{x - \frac{x^2}{2}} dx}_k = \frac{k}{e^b}$$

לכן קצב הירידה הוא אקספוננציאלי ולא ריבועי.

8.9 אי שיויון ינסן

ידוע לנו ש-

$$\mathbb{E}X^2 \geq (\mathbb{E}X)^2$$

כי ההפרש ביניהם הוא השונות והיא מספר חיובי.
עבור $h(t) = t^2$ ניתן לרשום את אי השוויון בתור:

$$\mathbb{E}h(X) \geq h(\mathbb{E}X)$$

משפט 8.9 אם h פונקציה קמורה אז לכל משתנה מקרי X מתקיים $\mathbb{E}h(X) \geq h(\mathbb{E}X)$
לדוגמה, $h(t) = |t|^n$ קמורה לכל $n > 1$ לכן

$$\mathbb{E}X^n \geq (\mathbb{E}X)^n$$

גם $|t|^\alpha$ קמורה עבור $\alpha > 1$.

$$(\mathbb{E}|X|^n)^{\frac{1}{n}} \geq (\mathbb{E}|X|^m)^{\frac{1}{m}} \geq (|X|^m)^{\frac{1}{n}}$$

הגדרה 8.10 פונקציה $f: \mathbb{R} \rightarrow \mathbb{R}$ היא קמורה אם היא פונקציה שבה לכל שתי נקודות a, b הגרף של f בקטע $[a, b]$ נמצא מתחת למיתר המקשר את $(a, f(a))$ עם $(b, f(b))$.
לדוגמה, עבור נקודה האמצע של המיתר:

$$f\left(\frac{a+b}{2}\right) \leq \frac{1}{2}f(a) + \frac{1}{2}f(b)$$

באופן כללי לכל $\lambda, \mu \geq 0$ כך ש- $\lambda + \mu = 1$

$$f(\lambda a + \mu b) \leq \lambda f(a) + \mu f(b)$$

אם f גזירה פעמים אז f קמורה $\Leftrightarrow f'' \geq 0$.

הוכחה: הוכחת אי שוויון ינסן:

נכתוב את הגדרת הפונקציה הקמורה בסימון שונה. נניח שהנקודות הן a_1, a_2
והמשקלות הן λ_1, λ_2 כלומר $\lambda_i \geq 0$ ו- $\lambda_1 + \lambda_2 = 1$. אז

$$h(\lambda_1 a_1 + \lambda_2 a_2) \leq \lambda_1 h(a_1) + \lambda_2 h(a_2)$$

באינדוקציה מוכיחים שאם h קמורה אז לכל n ולכל a_1, \dots, a_n ולכל $\lambda_1, \dots, \lambda_n$ כאשר $\sum_{i=1}^n \lambda_i = 1$ ו- $\lambda_i \geq 0$ מתקיים

$$h\left(\sum_{i=1}^n \lambda_i a_i\right) \leq \sum_{i=1}^n \lambda_i h(a_i)$$

אם X דיסקרטי עם מספר סופי של ערכים, נניח ש- X מקבל את הערכים x_1, \dots, x_n בהסתברות p_1, \dots, p_n בהתאמה. אז

$$\mathbb{E}X = \sum_{i=1}^n p_i x_i$$

$$\mathbb{E}h(X) = \sum_{i=1}^n p_i h(x_i)$$

והטענה נובעת מהגדרת הקמירות.

$$h(\mathbb{E}X) = h\left(\sum_{i=1}^n p_i x_i\right) \leq \sum_{i=1}^n p_i h(x_i) = \mathbb{E}h(X)$$

■

8.10 פונקציה יוצרת מומנטים

נתון מ"מ X , אז הפונקציה יוצרת המומנטים שלו היא

$$M_X(s) = \mathbb{E}e^{sX}$$

היא מוגדרת עבור s ממשי בתנאי של- e^{sX} יש תוחלת.

דוגמאות $X \sim \exp(\lambda)$

$$\begin{aligned} M_X(s) &= \mathbb{E}e^{sX} \\ &= \int_0^\infty e^{sx} \lambda e^{-\lambda x} dx = \lambda \int_0^\infty e^{(s-\lambda)x} dx \\ &= \frac{\lambda}{s-\lambda} \left[e^{(s-\lambda)x} \right]_0^\infty = \begin{cases} \frac{\lambda}{s-\lambda} & s < \lambda \\ \infty & s \geq \lambda \end{cases} \end{aligned}$$

$X \sim \text{Geom}(p)$

$$\begin{aligned} M_X(s) &= \sum_{n \geq 1} e^{sn} p q^{n-1} \\ &= p e^s \sum_{n \geq 1} e^{s(n-1)} q^{n-1} \\ &= p e^s \sum_{n \geq 1} (e^s q)^{n-1} = \begin{cases} \frac{p e^s}{1 - e^s q} & s < -\log q \\ \infty & e^s q \geq 1 \end{cases} \end{aligned}$$

מהי הצורה הכללית של M_X כאשר יש ל- X צפיפות?

$$M_X(s) = \mathbb{E}e^{sX} = \int_{-\infty}^\infty e^{sx} f_X(x) dx$$

תוצאה זו מאוד דומה לטרנספורם לפלס של f_X .

8.10.1 תחום ההגדרה של M_X

$M_X(0) = 1$ לכל X .

טענה 8.11 תחום ההגדרה של M_X הוא תמיד קטע (כולל אפשרות של קרן אינסופית או כל הישר).

כלומר, תחום ההגדרה הוא קבוצה קמורה בישר.

הוכחה: נקבע שתי נקודות s_1, s_2 עבורם $M_X(s_i) < \infty$
נבחר $s_1 < s < s_2$ ונציג אותו כממוצע של s_1, s_2 :

$$s = \lambda s_1 + (1 - \lambda) s_2$$

כאשר $0 < \lambda < 1$.

נשתמש בקמירות של הפונקציה $h(t) = e^t$

$$\begin{aligned} M_X(s) &= \mathbb{E}e^{sX} = \\ &= \mathbb{E}e^{\lambda s_1 X + (1-\lambda)s_2 X} \leq \lambda \mathbb{E}e^{s_1 X} + (1-\lambda) \mathbb{E}e^{s_2 X} \\ &= \lambda M_X(s_1) + (1-\lambda) M_X(s_2) < \infty \end{aligned}$$

■

נחשב את הנגזרת של $M_X(s)$:
אם X רציף:

$$M'_X(s) = \frac{d}{ds} \int_{-\infty}^{\infty} e^{sx} f_X(x) dx = \int_{-\infty}^{\infty} x e^{sx} f_X(x) dx = \mathbb{E}X e^{sX} = \mathbb{E}(e^{sX})'$$

אם X בדיד:

$$M'_X(s) = \frac{d}{ds} \sum e^{sx_n} p_n = \sum x_n e^{sx_n} p_n = \mathbb{E}X e^{sX} = \mathbb{E}(e^{sX})'$$

נניח שמותר לגזור בתוך סימן התוחלת, ואז

$$M'_X(s) = \mathbb{E}X e^{sX}$$

נציב $s = 0$ ונקבל

$$M'_X(0) = \mathbb{E}X$$

$$M''_X(s) = \mathbb{E}X^2 e^{sX}$$

$$M_X^{(k)}(s) = \mathbb{E}X^k e^{sX}$$

ושוב נציב $s = 0$ ונקבל

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

כלומר קיבלנו את המומנט ה- k של X .

משפט 8.12 נניח ש- $M_X(s)$ מוגדרת וגזירה k פעמים בסביבת הנקודה $s = 0$, אז יש ל- X מומנט k -י והוא ניתן ע"י:

$$M_X^{(k)}(0) = \mathbb{E}X^k = m_k$$

דוגמה $X \sim \exp(\lambda)$ מהו m_{39} ?
 כבר חישבנו ש-

$$\begin{aligned} M_X(s) &= \frac{\lambda}{s-\lambda} = \frac{1}{\frac{s}{\lambda}-1} = -\frac{1}{1-\frac{s}{\lambda}} = -\sum_{n=0}^{\infty} \left(\frac{s}{\lambda}\right)^n = -\sum_{n=0}^{\infty} \lambda^{-n} s^n \\ &= \sum_{n=0}^{\infty} \frac{M_X^{(n)}(0)}{n!} s^n \end{aligned}$$

לכן מהשוואת מקדמים נקבל

$$M_X^{(n)}(0) = -\frac{n!}{\lambda^n}$$

8.11 הפונקציה האופיינית (Characteristic Function)

לכל s ממשי נגדיר פונקציה אופיינית

$$\phi_X(s) = \mathbb{E}e^{isX}$$

במקרה הרציף נקבל ש-

$$\phi_X(s) = \int_{-\infty}^{\infty} e^{isx} f_X(x) dx$$

וזה דומה לטרנספורם פורייה של פונקצית הצפיפות.

8.11.1 חשיבות הפונקציה האופיינית

1. היא מוגדרת לכל X ולכל s ממשי, כי $|e^{isX}| = 1$ ולכן גם התוחלת היא מספר שערכו המוחלט הוא לכל היותר אחת.

2. אם לשני משתנים מקריים X ו- Y מתקיים $\phi_X(s) = \phi_Y(s)$ אז גם $F_X = F_Y$.

הערה 8.13 אם ϕ_X גזירה ניתן לגזור בתוך סימן התוחלת

$$\phi_X^{(k)}(s) = i^k \mathbb{E}X^k e^{isX}$$

ולכן

$$\phi_X^{(k)}(0) = i^k \mathbb{E}X^k = i^k m_k$$

9 וקטורים אקראיים

זורקים 2 מטבעות הוגנות ושואלים מהן התוצאות. חייבים לתת אינפורמציה על ההסתב-
רויות של כל התוצאות האפשריות, כלומר 4 מספרים $(p_{ij})_{(i,j=0,1)}$ שהם ההסתברות
שבשלב הראשון תתקבל התוצאה i ובשני j .

$$\begin{pmatrix} p_{00} & p_{01} \\ p_{10} & p_{11} \end{pmatrix}$$

ההסתברות שהמטבע הראשון יהיה 0 הוא סכום ההסתברויות בשורה הראשונה, כלומר
 $p_{00} + p_{01} = \frac{1}{2}$
ההסתברות שהמטבע השני יהיה 1 הוא סכום העמודה השנייה, וגם הוא $\frac{1}{2}$. למעשה
סכום כל עמודה וכל שורה הוא $\frac{1}{2}$. נסמן $p_{00} = t$, אז ניתן לסמן

$$\begin{pmatrix} t & \frac{1}{2} - t \\ \frac{1}{2} - t & t \end{pmatrix}$$

כל זה נובע מכך שהמטבע הוא הוגן. לכל $0 \leq t \leq \frac{1}{2}$ יש ניסוי אפשרי שמתאים לו,
כאשר t קובע את הקשר בין המטבעות.
נכליל למקרה כללי יותר. נניח שיש לנו שני משתנים מקריים X ו- Y שמקבלים
ערכים x_1, x_2, \dots ו- y_1, y_2, \dots בהסתברויות p_1, p_2, \dots ו- q_1, q_2, \dots בהתאמה.
נסמן

$$p_{ij} = P(X = x_i \wedge Y = y_j)$$

$$P(X = x_i) = \sum_{j=1}^{\infty} P(X = x_i \wedge Y = y_j) = \sum_{j=1}^{\infty} p_{ij}$$

9.1 וקטור מקרי בדיד

הגדרה 9.1 נאמר שהוקטור המקרי (X, Y) הוא וקטור מקרי בדיד, אם הוא יכול לקבל
מספר סופי או בן מניה של ערכים. אם הערכים הם (x_i, y_j) , אז לפונקציה $P_{(X,Y)}(i, j) = P(X = x_i \wedge Y = y_j)$
קוראים פונקציית ההסתברות של הוקטור המקרי.
בסימונים הנ"ל לפונקציית ההסתברות של X שנוסחתה היא

$$P(X = x_i) = \sum_j P_{(X,Y)}(i, j)$$

ולפונקציית ההסתברות של Y שניתנת ע"י

$$P(Y = y_j) = \sum_i P_{(X,Y)}(i, j)$$

אנו קוראים פונקציות ההסתברות השוליות.
פונקציית ההתפלגות של הוקטור (X, Y) היא הפונקציה

$$F_{XY}(x, y) = P(X \leq x \wedge Y \leq y)$$

אם $X = (X_1, \dots, X_n)$ וקטור n -ממדי, אז פונקציית ההסתברות שלו היא

$$P_{X_1, \dots, X_n}(x_1, \dots, x_n) = P(X_1 = x_1 \wedge \dots \wedge X_n = x_n)$$

ופונקציית ההתפלגות היא

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) = P(X_1 \leq x_1 \wedge \dots \wedge X_n \leq x_n)$$

פונקציית ההסתברות השולית הן

$$P_{X_i}(x) = \sum P_{X_1, \dots, \hat{X}_i, \dots, X_n}(x_1, \dots, x, \dots, x_n)$$

כלומר סוכמים את כל האפשרויות בהן המשתנה X_i מקבל את הערך x .

דוגמא (X, Y) וקטור מקרי דיסקרטי, כאשר $P((x, y) = (i, j)) = c2^{-j}$ $1 \leq i \leq j < \infty$.

ההסתברות השולית של X היא

$$P_X(i) = \sum_{j \geq i} c2^{-j} = \frac{c}{2^{i-1}}$$

וההסתברות השולית של Y :

$$P_Y(j) = \sum_{i=1}^j c2^{-j} = jce2^{-j}$$

ניתן לחשב את c על ידי המשוואה $\sum_{i,j} c2^{-j} = 1$ בדרך אחרת:

$$P_X(i) = 2c \frac{1}{2} 2^{-(i-1)}$$

אבל זוהי בדיוק ההסתברות של משתנה מקרי גיאומטרי עם פרמטר $\frac{1}{2}$. לכן $c = \frac{1}{2} \Leftrightarrow 2c = 1$.

9.2 וקטור אקראי רציף

הגדרה 9.2 וקטור אקראי הוא רציף אם יש פונקציה $f_{X,Y}$ הנקראת פונקציית הצפיפות של הוקטור, כך שלכל $a_1 < b_1$ ו- $a_2 < b_2$

$$P(a_1 \leq X \leq b_1 \wedge a_2 \leq Y \leq b_2) = \int_{a_1}^{b_1} \int_{a_2}^{b_2} f_{X,Y}(x, y) dy dx$$

f חייבת להיות חיובית, ו- $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f = 1$. f יחידה עד כדי שינוי שלא משנה ערך של אינטגרלים.

הגדרה 9.3 פונקצית ההתפלגות של וקטור רציף היא

$$\begin{aligned} F_{X_1, \dots, X_n}(x_1, \dots, x_n) &= P(X_1 \leq x_1 \wedge \dots \wedge X_n \leq x_n) \\ &= \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f_{\vec{X}}(t_1, \dots, t_n) dt_n \dots dt_1 \end{aligned}$$

באופן כללי יותר

$$P(\vec{X} \in A) = \int_A f_{\vec{X}} dx_1 \dots dx_n$$

ההתפלגות השולית במקרה הדו ממדי תהיה

$$F_X(x) = \int_{-\infty}^x \int_{-\infty}^{\infty} f_{XY}(s, t) dt ds$$

נקבל את הצפיפות השולית על ידי גזירה לפי x :

$$f_X(x) = \int_{-\infty}^{\infty} f_{X,Y}(x, t) dt$$

9.2.1 תכונות פונקצית ההתפלגות

$$F_{XY}(x, y) = P(X \leq x \wedge Y \leq y)$$

$$0 \leq F_{XY}(x, y) \leq 1 \quad .1$$

$$\lim_{x \rightarrow -\infty} F_{XY}(x, y) = 0 \quad \text{לכל } y. \quad .2$$

$$\lim_{x \rightarrow \infty} F_{XY}(x, y) = P(Y \leq y) = F_Y(y) \quad .3$$

4 עבור הריבוע $(x, y), (x+a, y), (x, y+b), (x+a, y+b)$ $(a, b \geq 0)$ ההסתברות-
ות שנקבל וקטור בתוך הריבוע היא בוודאי אי שלילית.
הסתברות זו שווה ל-

$$F_{XY}(x+a, y+b) - F_{XY}(x, y+b) - F_{XY}(x+a, y) + F_{XY}(x, y) \geq 0$$

9.3 משתנים מקריים בלתי תלויים

הגדרה 9.4 יהי (X_1, \dots, X_n) וקטור מקרי עם פונקצית התפלגות משותפת F_{X_1, \dots, X_n} . נאמר שהמ"מ X_1, \dots, X_n (רכיבי הוקטור) הם בלתי תלויים אם

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) = F_{X_1}(x_1) F_{X_2}(x_2) \cdots F_{X_n}(x_n)$$

למשל בשני ממדים:

$$F_{XY}(x, y) = F_X(x) F_Y(y)$$

כלומר ההסתברות ש- $X \leq x$ וגם $Y \leq y$ שווה למכפלת ההסתברויות הנ"ל.

$$F_{XY}(x, y) = P(X \leq x \wedge Y \leq y) = P(X \leq x) P(Y \leq y) = F_X(x) F_Y(y)$$

ההגדרה למעלה אומרת שמידע על אחד המאורעות $X \leq x$ או $Y \leq y$ אינו תורם אינפורמציה להסתברות של המאורע האחר. באופן אינטואיטיבי אי התלות פירושה שלכל שתי קבוצות A, B מתקיים

$$P(X \in A \wedge Y \in B) = P(X \in A) P(Y \in B)$$

ולא רק עבור $A = \{X \leq x\}$, $B = \{Y \leq y\}$.

טענה 9.5 אם (X, Y) ב"ת, הדרישה הזו אכן מתקיימת.

הערה 9.6 אם X_1, \dots, X_n בלתי תלויים ויש וקטור צפיפות, אז מתקיים

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = f_{X_1}(x_1) \cdots f_{X_n}(x_n)$$

ולהפך. ניתן להוכיח על ידי גזירת פונקצית ההתפלגות של הוקטור.

הוכחה: במקרה הרציף:
ידוע

$$F_{XY}(x, y) = F_x(x) F_y(y)$$

ולכן

$$f_{XY}(x, y) = f_X(x) f_Y(y)$$

כעת נחשב את ההסתברות

$$\begin{aligned}
 P(X \in A \wedge Y \in B) &= \int \int_{A \times B} f_{XY}(x, y) dx dy \\
 &= \int \int_{A \times B} f_X(x) f_Y(y) dx dy \\
 &= \int_B \left(\int_A f_X(x) f_Y(y) dx \right) dy \\
 &= \int_B f_Y(y) \left(\int_A f_X(x) dx \right) dy \\
 &= \int_B f_Y(y) P(X \in A) dy \\
 &= P(X \in A) \int_B f_Y(y) dy \\
 &= P(X \in A) P(Y \in B)
 \end{aligned}$$

■

פונקציית הצפיפות f_{XY} של משתנים בלתי תלויים נראית כמו מלבן, או אוסף מלבנים, מכיוון שבכל תחום שעבורו $f_X > 0$ ו- $f_Y > 0$ יקבל ערך חיובי.

דוגמאות

1. $X \sim U(0, 1)$, $Y \sim U(0, 1)$ והם בלתי תלויים. איך מתפלג הוקטור (X, Y) ?
הצפיפות של X היא

$$\begin{aligned}
 f_X(x) &= 1 \quad 0 \leq x \leq 1 \\
 f_Y(y) &= 1 \quad 0 \leq y \leq 1
 \end{aligned}$$

$$\begin{aligned}
 f_{XY}(x, y) &= f_X(x) f_Y(y) \\
 &= 1 \quad 0 \leq x, y \leq 1
 \end{aligned}$$

זוהי התפלגות אחידה בריבוע. כלומר ההסתברות ש- (X, Y) נמצא בתחום D כלשהו היא השטח של $D \cap R$ (כאשר R הוא ריבוע היחידה).

באופן כללי, אם $R \subset \mathbb{R}^2$ תחום חסום כלשהו, אז התפלגות אחידה ב- R פירושה וקטור אקראי (X, Y) כך שההסתברות שניפול בתחום $D \subset \mathbb{R}^2$ פרופורציונאלית לשטח של $D \cap R$.

2. $R = \{x^2 + y^2 \leq 1\}$ עיגול היחידה.

$$f_{XY}(x, y) = \frac{1}{\pi} \quad (x, y) \in R$$

$$f_X(x) = \int_{-\infty}^{\infty} f_{XY}(x, y) dy = \int_{-\sqrt{1-x^2}}^{\sqrt{1-x^2}} \frac{1}{\pi} dy = \frac{2\sqrt{1-x^2}}{\pi}, \quad |x| \leq 1$$

$$f_X(x) = 0, \quad |x| \geq 1$$

המשתנים X ו- Y תלויים: אם נדע מידע כלשהו על X בוודאי שהדבר ישפיע על ההתפלגות של Y , ומעבר לכך אפשר לראות שמכפלת f_X ב- f_Y איננה פונקציה הצפיפות f_{XY} .

3. $f_{XY}(x, y) = cx^4y^2$, $x^2 + y^2 \leq 1$ פונקציה זו איננה מתארת משתנים בלתי תלויים, למרות שהיא מכפלה של פונקציה של x בפונקציה של y , מכיוון שהתחום שבו הפונקציה נתמכת איננו מלבני, ובתחום שמחוץ לעיגול היחידה הפונקציה איננה מכפלה של הפונקציות המתאימות.

4. $X_1 \sim \exp(\lambda_1)$, $X_2 \sim \exp(\lambda_2)$ והם ב"ת. מהי ההסתברות ש- X_2 גדול מ- X_1 ?

$$P(X_2 > X_1) = \int \int_M f_{X_1, X_2}(x_1, x_2) dx_1 dx_2$$

כאשר M הוא המשולש שמעל הקו $x = y$ ברביע הראשון.

$$\begin{aligned} P(X_2 > X_1) &= \int_0^\infty \int_{x_1}^\infty f_{X_1}(x_1) f_{X_2}(x_2) dx_2 dx_1 \\ &= \int_0^\infty \int_{x_1}^\infty \lambda_1 e^{-\lambda_1 x_1} \lambda_2 e^{-\lambda_2 x_2} dx_2 dx_1 \\ &= \lambda_1 \int_0^\infty e^{-\lambda_1 x_1} \int_{x_1}^\infty \lambda_2 e^{-\lambda_2 x_2} dx_2 dx_1 \\ &= \lambda_1 \int_0^\infty e^{-\lambda_1 x_1} e^{-\lambda_2 x_1} dx_1 \\ &= \lambda_1 \int_0^\infty e^{-(\lambda_1 + \lambda_2)x_1} dx_1 \\ &= \frac{\lambda_1}{\lambda_1 + \lambda_2} \end{aligned}$$

5. נניח ש- X_i ארכי החיים של רכיבים המחוברים בטור. X אורך החיים של המערכת כולה.

נניח ש- $X_i \sim \exp(\lambda)$, ו- X_i בלתי תלויים. מהי ההתפלגות של X ?

$$X = \min \{X_i\}$$

$$\begin{aligned} P(X > x) &= P(\forall i : X_i > x) \\ &= \prod_{i=1}^n P(X_i > x) = \prod_{i=1}^n e^{-\lambda x} = e^{-(\lambda n)x} \end{aligned}$$

אז פונקציית ההתפלגות של X היא

$$F_X(x) = 1 - P(X > x) = 1 - e^{-(\lambda n)x}$$

כלומר $X \sim \exp(\lambda n)$.

6. $X, Y \sim N(0, 1)$, והם בלתי תלויים. נסמן $R = \sqrt{X^2 + Y^2}$. מה ההתפלגות של R ?

$$\begin{aligned} r > 0, \quad P(R \leq r) &= \int \int_{X^2 + Y^2 \leq r^2} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} dx dy \\ &= \frac{1}{2\pi} \int_0^{2\pi} \int_0^r e^{-\frac{\rho^2}{2}} \rho d\rho d\theta \\ &= \int_0^r e^{-\frac{\rho^2}{2}} \rho d\rho \\ &= \left[-e^{-\frac{\rho^2}{2}} \right]_0^r = 1 - e^{-\frac{r^2}{2}} \end{aligned}$$

$$f_R(r) = r e^{-\frac{r^2}{2}}, \quad r > 0$$

התפלגות זו נקראת התפלגות ריילי.

7. בתחנת שירות זמן השירות של כל לקוח מתפלג עם צפיפות f_{X_i} . ע"פ התור אני נכנס שלישי. כמה זמן אצטרך לחכות לתורי, מאז פתיחת התחנה?
אם X_i זמן השהות של הלקוח ה- i , וכולנו הגענו לפני זמן הפתיחה, זמן ההמתנה שלי הוא $X_1 + X_2$. נניח גם ש- X_i בלתי תלויים.

$$\begin{aligned} P(X_1 + X_2 \leq x) &= \int \int_A f_{X_1}(x_1) f_{X_2}(x_2) dx_2 dx_1, \quad A = \{x_1 + x_2 \leq x\} \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{x-x_1} f_{X_2}(x_2) f_{X_1}(x_1) dx_2 dx_1 \end{aligned}$$

לחישוב הצפיפות נגזור

$$f_X(x) = \int_{-\infty}^x f_{X_1}(x_1) f_{X_2}(x-x_1) dx_1$$

כלומר f_x היא הקונבולוציה של הצפיפויות.

$$f_{X_1+X_2} = f_{X_1} * f_{X_2}$$

כאשר X_1 ו- X_2 בלתי תלויים.

נניח בדוגמה ש- $X_i \sim \exp(\lambda)$

$$\begin{aligned} f_{X_1+X_2}(x) &= \int_0^x \lambda e^{-\lambda x_1} \lambda e^{-\lambda(x-x_1)} dx_1 \\ &= \lambda^2 x e^{-\lambda x} \end{aligned}$$

הגדרה 9.7 התפלגות גמא $X \sim \text{Gamma}(r, \lambda)$ ניתנת ע"י הצפיפות

$$f_X(x) = \frac{\lambda^r x^{r-1} e^{-\lambda x}}{(r-1)!} \quad x \geq 0$$

זוהי הצפיפות של $X = X_1 + \dots + X_r$ כאשר $X_i \sim \exp(\lambda)$ והם ב"ת.