

גירסה 1.02 - 12.4.2005



מבוא להסתברות והתפלגויות - סיכום נקודות (חלק שני)

מסמך זה הורד מהאתר <http://underwar.livedns.co.il> אין להפיץ מסמך זה במדיה כלשהי, ללא אישור מפורש מאת המחבר. מחבר המסמך איננו אחראי לכל נזק, ישיר או עקיף, שיגרם עקב השימוש במידע המופיע במסמך, וכן לנכונות התוכן של הנושאים המופיעים במסמך. עם זאת, המחבר עשה את מירב המאמצים כדי לספק את המידע המדויק והמלא ביותר.

כל הזכויות שמורות לניר אדר

Nir Adar

Email: underwar@hotmail.com

Home Page: <http://underwar.livedns.co.il>

אנא שלחו הערות ותיקונים אל המחבר.

גרסאות

גירסה 1.02 – 12.4.2005
- תוקנו מספר שגיאות כתיב.

גירסה 1.01 - 30.10.2002
- תוקנו מספר דקויות בטקסט. תודה לליאור קהתי שהעיר לגבי אי הדיוקים.

גירסה 1.00 - 5.7.2002

תוחלת של פונקציה של מ"מ

X מ"מ כלשהו (רציף) ו- $g(x)$ פונקציה ממשית.
מהי התוחלת של המ"מ $Y = g(X)$?

יש למצוא את פונקצית הצפיפות של Y - $f_Y(y)$ ולבצע אינטגרל $EY = \int_{-\infty}^{\infty} yf(y)dy$.

משפט

תהי $g(x)$ פונקציה ממשית כלשהי, אזי:
(א) אם X משתנה מקרי רציף עם פונקצית צפיפות $f(x)$ אזי:

$$E(g(X)) = \int_{-\infty}^{\infty} g(x)f(x)dx$$

(ב) אם X מ"מ בדיד עם הסתברות $P(X = x_i) = p_i$ אזי: $E(g(X)) = \sum_i p_i g(x_i)$

מסקנות מיידיות מהמשפט

1. אם X קבוע ($X = c$) אזי $EX = c$.
(מכיוון ש $EX = \int cf(x)dx = c$.)
2. אם X מ"מ ו- a, b קבועים, אז $E(aX + b) = aE(X) + b$.

הוכחה



$$E(aX + b) = \int (ax + b) \cdot f(x)dx = a \int xf(x)dx + b \int f(x)dx = aE(X) + b$$

3. (נובע מ-2) אם X מ"מ מתוך פילוג נורמלי $X \sim N(\mu, \sigma^2)$ אזי $E(X) = \mu$.

משפט

אם X משתנה מקרי (רציף או בדיד) אי שלילי, ו- $F_X(x)$ פונקצית ההתפלגות שלו, אזי:

$$E(X) = \int_0^{\infty} [1 - F_X(x)]dx = A$$



מומנט

המומנט ה-n-י של מ"מ X הוא $E(X^n)$. אם X בדיד אז $E(X^n) = \sum_i x_i^n \cdot p_i$ ואם X

$$רציף, אזי $E(X^n) = \int_{-\infty}^{\infty} x^n \cdot f(x) dx$.$$

שונות (Variance)

שונות היא מדד לפיזור המ"מ סביב התוחלת שלו. נבחר את המדד להיות $E((X - \mu)^2)$. השונות היא בעצם מומנט מסדר שני של $X - \mu$.

סטיית התקן של X היא $\sigma = \sqrt{\text{Var}(X)}$ והיא באותן יחידות של X, ולכן נוה להשתמש ב σ כמדד לפיזור.

נוסחה נוחה לחישוב השונות

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

שונות וסטיית תקן של מספר משתנים ידועים

השונות	משתנה
$\text{var}(X) = \sigma^2$	$X \sim N(\mu, \sigma^2)$
$\text{var}(X) = pq$	$X \sim \text{Ber}(p)$
$\text{var}(X) = npq$	$X \sim \text{Bin}(n, p)$
$\text{var}(X) = \frac{1-p}{p^2}$	$X \sim \text{Geom}(p)$
$\text{var}(X) = \lambda$	$X \sim \text{Pois}(\lambda)$

תכונות אחדות של השונות

$$1. \quad \text{Var}X \geq 0$$

$$\text{Var}X = 0 \Leftrightarrow X = \text{const}$$

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


- השונות מתארת פיזור סביב התוחלת
- משפיע על התוחלת אבל לא על השונות.

$$\sigma(aX + b) = |a| \cdot \sigma(X)$$


טענה

X מ"מ.

$$\text{Var}X = E(X - \mu)^2 = \min_b E(X - b)^2$$

החציון

(M=medium)



$$\int_{-\infty}^M f(x) dx = \frac{1}{2} = F(M) = P(X \leq M) : \text{החציון מקיים}$$

אם X משתנה בדיד, אזי אם יש N עבורו $\sum_{i=1}^N p_i = \frac{1}{2}$ אזי $x_i = M$

ואם $\sum_{i=1}^N p_i < \frac{1}{2} < \sum_{i=1}^{N+1} p_i$ אזי $M = \frac{x_i + x_{i+1}}{2}$.

משפט

X מ"מ רציף ו M_x החציון שלו, אזי $E|X - M_x| \leq E|X - b|$, $\forall b$.

אי שוויון מרקוב (Markov)

יהי X מ"מ אי שלילי בעל תוחלת EX סופית, אזי לכל מספר $a > 0$ מתקיים

$$P(X \geq a) \leq \frac{EX}{a}$$

X יכול להיות רציף, בדיד או מעורב.

אי שיוויון צובישב (Chebyshev)

X מ"מ, μ התוחלת שלנו, ו- σ^2 השונות שלו, אזי לכל $a > 0$, $P(|X - \mu| \geq a) \leq \frac{\sigma^2}{a^2}$

אי שוויון ינסן (Jensen)

אם X הוא מ"מ בעל תוחלת סופית EX וגם f קמורה, אזי $E(f(X)) \geq f(EX)$.
אם f קעורה, אזי $E(f(X)) \leq f(EX)$.

תזכורת

$$E(X - \mu) = EX - E\mu = EX - \mu = EX - EX = 0 \Rightarrow \int f(x)(x - \mu)dx = 0$$

משפט

X מ"מ רציף עם פונקציה צפיפות $f_X(x)$. $g(x)$ היא פונקציה עולה ממש או יורדת ממש על (a, b) . (a, b) יכולים להיות גם $(\pm\infty)$.
נגדיר מ"מ $Y = g(X)$ אזי:

$$f_Y(y) = \begin{cases} f_X(g^{-1}(y)) \cdot \left| \frac{d}{dy}(g^{-1}(y)) \right| & y \in g(a, b) = \{y | \exists x \in (a, b), y = g(x)\} \\ 0 & y \notin g(a, b) \end{cases}$$

ניסוח נוסף:

$$f_Y(y) = \begin{cases} \frac{f_X(x)}{\left| \frac{d}{dx} g(x) \right|} & \{x | g(x) = y\} \\ 0 & \{x | g(x) = \emptyset\} \end{cases}$$

סקירת ההוכחה

$$F_Y(y) = P(Y \leq y) = P(g(x) \leq y) = \begin{cases} P(X \leq g^{-1}(y)) & g \text{ rise} \\ P(X \geq g^{-1}(y)) & g \text{ fall} \end{cases}$$

נגזור את הביטוי ונקבל משל.

פונקציה יוצרת מומנטים

עבור משתנה מקרי X (רציף או בדיד) נגדיר $\phi(t) = M(t) = E(e^{tX})$, $t \in \mathbb{R}$

עבור X רציף: $\phi(t) = \int_{-\infty}^{\infty} e^{tX} f(x) dx$

עבור X בדיד: $\phi(t) = \sum_i e^{tX} p_i$

חישוב של פונקציות יוצרות מומנטים

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

$$\phi(t) = e^{t \cdot 1} \cdot p + e^{t \cdot 0} \cdot q = \boxed{p \cdot e^t + q}$$

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

$$\phi_X(t) = \sum_{k=0}^n e^{tk} \binom{n}{k} p^k (1-p)^{n-k} = \sum_{k=0}^n \binom{n}{k} (e^t \cdot p)^k q^{n-k} = (e^t p + q)^n$$

$(\lambda > 0)$, $X \sim \text{Pois}(\lambda)$

$$\phi(t) = Ee^{tX} = \sum_{k=0}^{\infty} e^{tk} \cdot \frac{\lambda^k}{k!} \cdot e^{-\lambda} = \sum_{k=0}^{\infty} \frac{(e^t \lambda)^k \cdot e^{-\lambda}}{k!} = e^{-\lambda} \cdot e^{e^t \lambda} = \boxed{e^{\lambda e^t - \lambda}}$$

$X \sim \text{Exp}(\lambda)$

$$\phi(t) = E(e^{tX}) = \int_0^{\infty} e^{tx} \lambda e^{-\lambda x} dx = \lambda \int_0^{\infty} e^{(t-\lambda)x} dx = \frac{x}{t-\lambda} e^{(t-\lambda)x} \Big|_0^{\infty} = \boxed{\frac{x}{\lambda-t}}$$

$X \sim N(0,1)$

$$Ee^{tX} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{tx} e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(x^2 - 2tx)} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}[(x-t)^2 - t^2]} dx = e^{\frac{t^2}{2}}$$

$$\boxed{\phi(t) = e^{\frac{t^2}{2}}}$$

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

$X = \sigma Z + \mu$ when $Z \sim N(0,1)$

$$\phi(t) = e^{\frac{1}{2}(t^2 \sigma^2 + 2t\mu)}$$

פונקציה אופיינית של מ"מ X

$$\varphi_X(t) = Ee^{itX}$$

i - מספר מרוכב.

$$e^{it} = \cos t + i \sin t$$

אם tx ממשי, אזי $|e^{itx}| = 1$.

$$M(t) = e^{t^2/2}$$

עבור $X \sim N(0,1)$:

$$\varphi(t) = e^{-t^2/2}$$

משתנה מקרי דו ממדי או ווקטור אקראי

זוג (X, Y) , כאשר X, Y מ"מ, נקרא משתנה מקרי דו ממדי או ווקטור דו ממדי.

באופן כללי:

n-יה (X_1, X_2, \dots, X_n) כאשר X_1, X_2, \dots, X_n מ"מ, תקרא מ"מ n-ממדי או ווקטור מקרי n-ממדי.

פונקציות ההתפלגות המשותפת של (X, Y) תהיה הפונקציה:

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

הפונקציות $F_X(x), F_Y(y)$ נקראות פונקציות ההתפלגות השוליות של (X, Y) . אפשר לקבל כי:

$$F_X(a) = P(X \leq a) = P(X \leq a, y < \infty)$$

$$= \lim_{b \rightarrow \infty} P(X \leq a, y \leq b) = \lim_{b \rightarrow \infty} F_{XY}(a, b) \equiv F(a, \infty^-)$$

$$F_Y(b) \equiv F(\infty^-, b)$$

עבור (X, Y) בדיד (כלומר X בדיד וY בדיד) שמקבל רק מספר סופי או בן מניה של נקודות במישור, מגדירים את פונקציות ההסתברות המשותפת:

$$P(x_i, y_j) = P(X = x_i, Y = y_j)$$

פונקציות ההסתברות $P_X(x_i), P_Y(y_j)$ נקראות פונקציות ההסתברות השוליות של (X, Y) .

פונקציות ההתפלגות המשותפת

(X, Y) בדיד, $P_{XY}(x_i, y_j)$ היא פונקציות ההסתברות המשותפת.

נגדיר $F_{XY}(x, y)$ פונקציות ההתפלגות המשותפת. F מוגדרת לכל x ולכל y.

$$F_{XY}(x, y) = P(X \leq x, Y \leq y) = \sum_{\substack{x_i < x \\ y_j < y}} P(X = x_i, Y = y_j)$$

משתנה מקרי דו ממדי רציף

מ.מ. זה מקבל רצף של ערכים במישור. באופן פורמלי, מ"מ דו ממדי יקרא רציף, אם קיימת $f(x, y)$ כך ש:

א. $f(x, y) \geq 0$ לכל x, y .

ב. על כל תת קבוצה D במישור xy , מתקיים: $P((x, y) \in D) = \iint_D f(x, y) dx dy$

פונקצית צפיפות

יהי (X, Y) רציף,

$$F_{XY}(x, y) = P(X \leq x, Y \leq y) = \int_{-\infty}^x dx \int_{-\infty}^y f(x, y) dy$$

$$\frac{\partial F}{\partial x}(x, y) = \int_{-\infty}^y f(x, y) dy$$

$$\frac{\partial}{\partial y} \left(\frac{\partial F}{\partial x}(x, y) \right) = f(x, y)$$

$$\boxed{f(x, y) = \frac{\partial^2 F}{\partial x \partial y} = F''_{xy}(x, y)} \quad \text{כלומר}$$

טענה

$$P(x \leq X \leq x + dx, y \leq Y \leq y + dy) \approx f(x, y) dx dy$$

טענה

תהי פונקצית הצפיפות $f_{\bar{x}}(x_1, x_2, \dots, x_n)$ פונקצית ההתפלגות:

$$F_{\bar{x}}(x_1, x_2, \dots, x_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$$

$$F = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_n} f(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n$$

$$f_{\bar{x}}(x_1, x_2, \dots, x_n) = \frac{\partial^n}{\partial x_1 \partial x_2 \dots \partial x_n} F(x_1, x_2, \dots, x_n)$$

משתנה מקרי אחיד ב- R^2

$(X, Y) \sim u(D)$, הוא תחום פשוט וחסום ב- R^2 . אם פונקצית הצפיפות שלו היא :

$$f(x, y) = \begin{cases} \frac{1}{Area(D)} & (x, y) \in D \\ 0 & (x, y) \notin D \end{cases}$$

התפלגות מולטינומית

נעשים n ניסיונות בלתי תלויים שבכל אחד מהם אפשרות לתוצאות עם הסתברויות

$$p_1, p_2, \dots, p_r \text{ כך ש-} \sum_{i=1}^r p_i = 1$$

$\bar{X} = (X_1, X_2, \dots, X_r)$, כאשר X_k זהו מספר הפעמים שהתוצאה ה- k הופיעה. מתקיים :

$$P_{\bar{X}}(n_1, n_2, \dots, n_r) = \frac{n!}{n_1! n_2! \dots n_r!} \cdot p_1^{n_1} \cdot p_2^{n_2} \cdot \dots \cdot p_r^{n_r}$$

$(n_1 + n_2 + \dots + n_r = n)$

הבינום של ניוטון

$$(x + y)^n = \sum_{k=0}^n \binom{n}{k} x^k y^{n-k}$$

נוסחת המולטינום

$$(x_1 + x_2 + \dots + x_r)^n = \sum \frac{n!}{n_1! n_2! \dots n_r!} \cdot x_1^{n_1} x_2^{n_2} \dots x_r^{n_r}$$

משתנים מקריים בלתי תלויים

שני משתנים מקריים X, Y הם בלתי תלויים אם עבור כל שתי קבוצות A ו- B ("מאורעות") מתקיים $P(X \in A, Y \in B) = P(X \in A) \cdot P(Y \in B)$, כלומר שני המאורעות $X \in A, Y \in B$ הם בלתי תלויים במובן ההסתברותי הרגיל.

סכומים של משתנים מקריים בלתי תלויים

ומתעניינים $\bar{X} = (X_1, X_2, \dots, X_n)$ משתנה מקרי n ממדי כאשר X_1, X_2, \dots, X_n בלתי תלויים

$$g(\bar{X}) = X_1 + X_2 + \dots + X_n$$

ב עבור X, Y ב"ת נסמן $W = X + Y$. W הוא משתנה מקרי. נחפש את F_W, f_W .
תהי $f(x, y)$ פונקצית הצפיפות של (X, Y) .

$$F_W(w) = P(W \leq w) = P(X + Y \leq w) = \iint_{x+y \leq w} f(x, y) dx dy = \dots = \int_{-\infty}^{\infty} f_X(x) \cdot F_Y(w-x) dx$$

זוהי פונקצית ההתפלגות של $W = X + Y$.
פונקצית הצפיפות היא הנגזרת של פונקצית ההתפלגות:

$$f_W(w) = F'_W(w) = \int_{-\infty}^{\infty} f_X(x) \cdot F'_Y(w-x) dx$$

זוהי קונבולוציה.

הגדרת קונבולוציה

יהיו f, g שתי פונקציות נתונות. נגדיר פעולה בין הפונקציות בשם קונבולוציה.
הפעולה מסומנת $f * g$.
ניקח f, g שתחום ההגדרה שלהן הוא \mathbb{R} . לכל $x \in \mathbb{R}$ נגדיר:

$$(f * g)(x) = \int_{-\infty}^{\infty} f(x-y)g(y)dy$$

בתנאי שהאינטגרל קיים. על ידי הצבה ניתן לראות כי מתקיים:

$$(f * g)(x) = \int_{-\infty}^{\infty} f(y)g(x-y)dy$$

ולכן נקבל כי $f * g = g * f$, כלומר פעולת הקונבולוציה היא פעולה קומוטטיבית.

טענה

$$F_W(w) = (F_X * f_Y)(W)$$

$$f_W(w) = (f_X * f_Y)(w)$$

טענות

.1

אם $X \sim N(\mu_1, \sigma_1^2), Y \sim N(\mu_2, \sigma_2^2)$ והם בלתי תלויים, אזי:
 $X + Y \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$

נכליל את התוצאה:

אם X_1, X_2, \dots, X_n בלתי תלויים ומפולגים נורמלית (μ_i, σ_i^2) כאשר $i = 1, 2, \dots, n$ אזי

$$\sum_{i=1}^n X_i \sim N\left(\sum_{i=1}^n \mu_i, \sum_{i=1}^n \sigma_i^2\right)$$

.2

אם $X \sim Pois(\lambda_1), Y \sim Pois(\lambda_2)$ בלתי תלויים אזי $X + Y \sim Pois(\lambda_1 + \lambda_2)$

.3

$X_i \sim Ber(p)$ כאשר $i = 1, 2, \dots, n$ וגם ה- X_i בלתי תלויים, אזי $\sum_{i=1}^n X_i \sim Bin(n, p)$

התפלגויות מותנות

תזכורת:

$$P(A|B) = \frac{P(AB)}{P(B)}, \quad P(B) > 0$$

פונקציה ההסתברות המותנית של משתנה מקרי בדיד:

$$P_{X|Y}(x|y) = P(X = x|Y = y) = \frac{P(X = x, Y = y)}{P(Y = y)} = \frac{P_{XY}(xy)}{P_Y(y)}$$

$$F_{X|Y}(x|y) = P(X \leq x|Y = y) = \sum_{x_i \leq x} P_{X|Y}(x_i|y)$$

אם X ו-Y בלתי תלויים, אזי:

$$P_{X|Y}(x|y) = \frac{P_X(x)P_Y(y)}{P_Y(y)} = P_X(x)$$

הסתברות מותנית רציפה

$$F_{X|Y}(x|y) = \frac{F(x, y)}{F_Y(y)}$$

תוחלת של פונקציה של (X, Y) עם פונקציה צפיפות f(x, y)

נתונה פונקציה g(x, y) סקלרית.

נגדיר: $W = g(X, Y)$.

$$EW = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f(x, y) dx dy$$

הליניאריות של התוחלת

$$E(X + Y) = EX + EY$$

ומכאן נוכל להסיק גם:

$$E(\alpha X + \beta Y) = \alpha EX + \beta EY$$

השונות

נסמן μ_1 התוחלת של X , μ_2 התוחלת של Y .

$$Var(X + Y) = Var(X) + 2COV(X, Y) + Var(Y)$$

הביטוי $COV(X, Y) = E(X - \mu_1)(Y - \mu_2)$ נקרא השונות המשותפת של המשתנים המקריים X, Y .

נכליל את הנוסחה הנ"ל ליותר מ-2 משתנים:

$$Var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n Var(X_i) + \sum_{i \neq j} COV(X_i, X_j)$$

מספר תכונות של $COV(X, Y)$

$$COV(X, X) = Var(X) \quad .1$$

$$COV(aX + b, cY + d) = ac \cdot COV(X, Y) \quad .2$$

שיטה לחישוב ה- COV

$$COV(X, Y) = E(XY) - E(X)E(Y)$$

משתנים מתואמים ולא מתואמים

X ו- Y יקראו לא מתואמים ביניהם אם $COV(X, Y) = 0$ או באופן שקול $Var(X + Y) = Var(X) + Var(Y)$ או $E(XY) = (EX)(EY)$.

משפט

אם X, Y הם בלתי תלויים, אזי הם בלתי מתואמים.

מקדם המתאם עבור שני משתנים מקריים X ו- Y

$$R(X, Y) = \rho(X, Y) = \frac{COV(X, Y)}{\sigma(X)\sigma(Y)}$$

תכונות מקדם המתאם :

1. ρ חסר יחידות.
2. $-1 \leq \rho(X, Y) \leq 1$
3. $\rho(X, Y) = \pm 1 \Leftrightarrow Y = aX + b$
4. אם $\rho = 0$ אז אומרים ש-X ו-Y אינם מתואמים כלל.

תוחלת מותנית

$$P_{X|Y}(x|y) = P(X = x | Y = y) = \frac{P_{X|Y}(x, y)}{P_Y(y)}$$

$$E(X | Y) = \sum_x x \cdot P_{X|Y}(x | y)$$

$$E(g(X) | Y) = \sum_x g(x) \cdot f_{X|Y}(X | Y)$$

$$EE(X | Y) \triangleq Eg_X(Y) = \sum_y g_X(y) \cdot P_Y(y)$$

משפט ההחלקה

$$EE(X | Y) = EX$$

תוחלת מותנית בווקטור מ"מ

$$E(X | \bar{Y})$$

$$EE(X | \bar{Y}) = EX \quad \text{לפי משפט ההחלקה :}$$

טרנספורמציות ווקטוריות

נתונה העתקה $\bar{g}(\bar{X}) = \bar{Y}$. נניח כי \bar{X}, \bar{Y} הם משתנים דו ממדיים.

אם $\bar{g} \in C^1$ וכן היא ח.ח.ע אז קיימת הטרנספורמציה ההפוכה, כך ש- $\bar{g}^{-1}(\bar{Y}) = \bar{X}$

יעקוביאן

$$J(X_1, X_2) = \frac{\partial(y_1, y_2)}{\partial(x_1, x_2)} = \begin{vmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_2}{\partial x_1} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} \end{vmatrix}$$

$$J^{-1}(Y_1, Y_2) = \frac{\partial(x_1, x_2)}{\partial(y_1, y_2)} = J^{-1}(X_1, X_2)$$

- נתונה פונקציה הצפיפות המשותפת $f_{\bar{X}}(X_1, X_2)$ ורוצים לדעת $f_{\bar{Y}}(y_1, y_2)$, אזי נשתמש בכך כי $f_{\bar{Y}}(y_1, y_2) = f_{\bar{X}}(x_1, x_2) \cdot |J(y_1, y_2)|$

פילוג Rayleigh

היהו משתנים מקריים X, Y , ונרצה לבצע את הטרנספורמציה $(X, Y) \rightarrow (R, \theta)$.
ההצבה תהייה:

$$\begin{aligned} x &= r \cos \theta & y &= r \sin \theta \\ x^2 + y^2 &= r^2 & j(r, \theta) &= r \end{aligned}$$

אם $X, Y \sim N(0, 1)$ מ"מ בלתי תלויים, אזי R מתפלג Rayleigh, ופונקצית הצפיפות

$$. f_R(r) = re^{-\frac{r^2}{2}} \text{ שלו היא}$$

אם $X, Y \sim N(0, \sigma)$ מ"מ בלתי תלויים, אזי R מתפלג Rayleigh, ופונקצית הצפיפות

$$\text{שלו היא } f_R(r) = re^{-\frac{r^2}{2\sigma^2}}, \text{ וגם } f_\theta(\theta) = \int_{r=0}^{\infty} \frac{re^{-\left(\frac{r^2}{2}\right)}}{2\pi} dr = \frac{1}{2\pi}$$

ומתקיים כי R, θ מ"מ בלתי תלויים.
לכן מתקיים:

$$f_{R,\theta}(r, \theta) = \frac{1}{2\pi} re^{-\frac{r^2}{2}}$$

הדמיית משתנה מקרי נורמלי בעזרת פילוג ריילי

1. מגרילים משתנה $u \sim (0, 1)$

$$.2 \quad R = \sqrt{2 \ln \frac{1}{1-u}}$$

3. מגרילים $\theta \sim u(0, 2\pi)$

$$.4 \quad X = R \cos \theta, Y = R \sin \theta$$

5. X, Y מפולגים שניהם נורמלית.

טרנספורמציה ליניארית - דוגמא

X, Y, Z מ"מ מקריים מפולגים $N(0,1)$ בלתי תלויים.
מבצעים טרנספורמציה ליניארית:

$$\begin{cases} U = X + Y + Z \\ V = X - Y \\ W = X - Z \end{cases}$$

או בצורה מטריצית:

$$\begin{pmatrix} U \\ V \\ W \end{pmatrix} = \begin{pmatrix} 1 & 1 & 1 \\ 1 & -1 & 0 \\ 1 & 0 & -1 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \end{pmatrix}$$

מיהי $f_{U,V,W}(u, v, w)$?

$$J(X, Y, Z) = \begin{vmatrix} 1 & 1 & 1 \\ 1 & -1 & 0 \\ 1 & 0 & -1 \end{vmatrix} = 3$$

$$J(U, V, W) = \frac{1}{3}$$

הטרנספורמציה ההפוכה:

$$X = \frac{U + V + W}{3}$$

$$Y = X - V = \frac{U + V + W}{3} - V$$

$$f_{U,V,W}(u, v, w) = \frac{1}{3} f_{X,Y,Z}(x, y, z) = \frac{1}{3} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} = \frac{1}{3} \cdot \frac{e^{-\frac{1}{2}(x^2+y^2+z^2)}}{(2\pi)^{3/2}}$$

משתנה נורמלי דו ממדי

X, Y מ"מ מפולגים נורמלים $N(\mu_1, \sigma_1^2), N(\mu_2, \sigma_2^2)$ בהתאמה (בי"ת).

אזי:

$$f_{X,Y}(x, y) = \frac{1}{\sqrt{2\pi\sigma_1^2}} \cdot e^{-\frac{(x-\mu_1)^2}{2\sigma_1^2}} \cdot \frac{1}{\sqrt{2\pi\sigma_2^2}} \cdot e^{-\frac{(y-\mu_2)^2}{2\sigma_2^2}} = \frac{1}{2\pi\sigma_1\sigma_2} e^{-\frac{1}{2}\left[\left(\frac{x-\mu_1}{\sigma_1}\right)^2 + \left(\frac{y-\mu_2}{\sigma_2}\right)^2\right]}$$

הגדרה

(X, Y) נקרא מ"מ נורמלי דו ממדי אם פונקציית הצפיפות שלו היא :

$$f(x, y) = \frac{1}{2\pi \cdot \sigma_1 \sigma_2 \sqrt{1 - \rho^2}} \cdot e^{-\frac{1}{2(1-\rho^2)} \left[\left(\frac{x-\mu_1}{\sigma_1} \right)^2 + \left(\frac{y-\mu_2}{\sigma_2} \right)^2 - 2\rho \frac{(x-\mu_1)(y-\mu_2)}{\sigma_1 \sigma_2} \right]}$$

הקווים $f(x, y) = c$ השקולים לקווים $k = \left(\frac{x-\mu_1}{\sigma_1} \right)^2 + \left(\frac{y-\mu_2}{\sigma_2} \right)^2 - 2\rho \frac{(x-\mu_1)(y-\mu_2)}{\sigma_1 \sigma_2}$ הם אליפסות בעלות יחס צירים קבוע סביב הנקודה (μ_1, μ_2) .

(X, Y) זוהי התפלגות נורמלית דו ממדית עם הפרמטרים $\mu_1, \mu_2, \sigma_1, \sigma_2, \rho$ כאשר $|\rho| < 1$.

תכונות של ההתפלגות הנורמלית הדו ממדית

1. $f(x, y) \geq 0$ כלומר פונקציית צפיפות, וגם $\iint_{\mathbb{R}^2} f(x, y) dx dy = 1$.

2. $X \sim N(\mu_1, \sigma_1), Y \sim N(\mu_2, \sigma_2)$ בדרך כלל משתנים אלו תלויים.

3. $\text{cov}(x, y) = \rho \sigma_1 \sigma_2$ ולכן $\rho(x, y) = \rho$.

4. קיים סיבוב בזווית α מסוימת שמעביר את (X, Y) ל- (U, V) , כאשר U, V משתנים מקריים מפולגים נורמלית ובלתי תלויים.

5. כל טרנספורמציה ליניארית הפיכה של (X, Y) מביאה למשתנה (U, V) שהוא נורמלי דו ממדי.

הפונקציה האופיינית של מ"מ מקרי X:

$$\varphi(t) = Ee^{itX} = \int e^{itX} f_X(x) dx$$

תכונות:

1. $\varphi(t)$ מוגדרת לכל t .

2. $|\varphi(t)| \leq 1$

3. $\Leftrightarrow \varphi_{aX+b}(t) = E^{i(aX+b)t} = Ee^{iatX} \cdot e^{ibt} = e^{ibt} E^{iatX} = e^{ibt} \varphi(at)$

4. מתקיים: $\varphi_{-X}(t) = \varphi_X(-t) = Ee^{-itX} = \overline{Ee^{itX}} = \overline{\varphi_X(t)}$

אם X סימטרי אזי $\varphi_{-X}(t) = \varphi_X(t) = \overline{\varphi_X(t)}$, ואז $\varphi_X(t)$ ממשי.

משפט

פונקציה אופיינית של קונבולוציה של התפלגויות היא מכפלת הפונקציות האופייניות.

תוחלת מותנית וחזאים

לפעמים בהינתן $X=x$, $(X$ מ"מ), אנו רוצים לחזות את ערך המשתנה המקרי Y , כלומר מחפשים y_0 שייתן מינימום לפונקציה $E((y - y_0)^2 | X = x)$.
 כבר ראינו כי $\min_a E(Y - a)^2 = E(Y - EY) = \text{var}(Y)$, כלומר המינימום מתקבל עבור $a = EY$.
 אותו דבר מתקיים כאשר המשתנה תלוי ב- X , כלומר, ה- y_0 הנותן את המינימום ל- $E((y - y_0)^2 | X = x)$ הוא בדיוק $E(Y | X = x)$.
 באופן כללי: $E(Y | X)$ הוא החזאי הכללי של Y בהינתן X .

חזאים ליניאריים

יהיו שני מ"מ X ו- Y . נניח שלא ידועה ההתפלגות המשותפת או שקשה לחשב את $E(Y | X = x)$. נניח שידועים μ_X, μ_Y , וכן השונות σ_X^2, σ_Y^2 ומקדם המתאם $\rho(X, Y)$.
 נחפש עתה מספרים a, b , כך ש: $E(Y - (a + bX))^2$ מהווה מינימום.

החזאי הליניארי הטוב ביותר עבור Y בהינתן X הוא $Y = \mu_Y + \rho \frac{\sigma_Y}{\sigma_X} (X - \mu_X)$