

טור	אינטגרל	נגזרת
$\sum_{k=0}^{\infty} ar^k = \frac{a}{1-r}$	$\int x^n dx = \frac{x^{n+1}}{n+1}$	$(x^n)' = nx^{n-1}$
$\sum_{k=0}^{n-1} ar^k = a \frac{1-r^n}{1-r}$	$\int \frac{1}{ax+b} dx = \frac{\log ax+b }{a}$	$(\log x)' = \frac{1}{x}, (e^x)' = e^x$
$\lim_{k \rightarrow \infty} \left(1 + \frac{a}{k}\right)^k = \sum_{k=0}^{\infty} \frac{a^k}{k!} = e^a$	$\int xe^x dx = e^x(x-1)$ $\int x^2 e^x dx = e^x(x^2 - 2x + 2)$	$(\sin x)' = \cos x, (\cos x)' = -\sin x$
$\sum_{k=1}^{\infty} ar^k = \frac{ar}{1-r}$	$\int \log(x) dx = x \log(x) - x$	$(f^{-1}(x))' = \frac{1}{f'(f^{-1}(x))}$
	$\int f'(x)g(x) dx = f(x)g(x) - \int f(x)g'(x) dx$	$(f(x)g(x))' = f'(x)g(x) + f(x)g'(x)$
		$(f(g(x)))' = f'(g(x))g'(x)$

בחירה עם סדר ללא החזרה	בחירה עם סדר ועם החזרה	בחירה ללא סדר וללא החזרה	בחירה ללא סדר ועם החזרה
$\binom{n+k-1}{k}$	$\binom{n}{k}$	$n^k$	$\frac{n!}{(n-k)!}$

שונות	תוחלת	MGF	CDF	PDF	שם ההתפלגות
$\frac{(b-a+1)^2 - 1}{12}$	$\frac{b+a}{2}$	$\frac{e^{as} - e^{(b+1)s}}{(b-a+1)(1-e^s)}$	$\frac{ x  - a + 1}{b-a+1}$	$\frac{1}{b-a+1}$	אחידה - בדיד $X \sim U(a, b)$
$p(1-p)$	$p$	$1 - p + pe^s$		$p^x(1-p)^{1-x}$	ברנולי $X \sim Ber(p)$
$np(1-p)$	$np$	$(1-p + pe^s)^n$		$\binom{n}{x} p^x (1-p)^{n-x}$	בינומית $X \sim Bin(n, p)$
$\frac{1-p}{p^2}$	$\frac{1}{p}$	$\frac{pe^s}{1-(1-p)e^s}$	$1 - (1-p)^k$	$(1-p)^{x-1} p$	גיאומטרית $X \sim Geo(p)$
	$\frac{mn}{k}$			$\frac{\binom{m}{x} \binom{n}{k-x}}{\binom{n+m}{k}}$	היפר-גיאומטרית $X \sim HG(k, n, m)$
$\lambda$	$\lambda$	$e^{\lambda(e^s-1)}$		$e^{-\lambda} \frac{\lambda^x}{x!}$	פואסון $X \sim Pois(\lambda)$
$\frac{(b-a)^2}{12}$	$\frac{b+a}{2}$	$\frac{e^{bs} - e^{as}}{(b-a)s}$	$\frac{x-a}{b-a}$	$\frac{1}{b-a}$	אחידה - רציף $X \sim U(a, b)$
$\frac{1}{\lambda^2}$	$\frac{1}{\lambda}$	$\frac{\lambda}{\lambda-s}$	$1 - e^{-\lambda x}$	$\lambda e^{-\lambda x}$	אקספוננציאלית $X \sim exp(\lambda)$
$\sigma^2$	$\mu$	$e^{\frac{s^2\sigma^2}{2} + s\mu}$		$\frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$	נורמלית $X \sim N(\mu, \sigma^2)$

בדיקת השערות	רווח סמך	אומד ניראות מירבית	סוג המדגם
$H_0: \theta = \theta_0$ $H_1: \theta = \theta_1 > \theta_0$ $\sum_{i=1}^n X_i \geq c$	בעזרת קירוב נורמלי וחסם על השונות $p \in \left[ X \pm \frac{z_{1-\frac{\alpha}{2}}}{\sqrt{n}} \right]$	$\hat{\theta}(X) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$	$X_1, \dots, X_n \sim Ber(\theta)$
	$\theta \in \left[ \max\{X_i\}, \frac{\max\{X_i\}}{\sqrt{\alpha}} \right]$	$\hat{\theta}(X) = \max\{X_i\}$	$X_1, \dots, X_n \sim U(0, \theta)$
$H_0: \theta = \theta_0$ $H_1: \theta = \theta_1 > \theta_0$		$\hat{\theta}(X) = 1/\bar{X}$	$X_1, \dots, X_n \sim exp(\theta)$

$\sum_{i=1}^n X_i \leq c$			
$H_0: \mu = \mu_0$ $H_1: \mu = \mu_1 > \mu_0$ $\frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \geq c$ יש גם מבחן הפוך יש גם מבחן דו-צדדי	$\mu \in \left[ \bar{X} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right]$	$\hat{\mu}(X) = \bar{X}$	$X_1, \dots, X_n \sim N(\mu, \sigma^2)$ כאשר השונות ידועה
		$\widehat{\sigma^2}(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)$	$X_1, \dots, X_n \sim N(\mu, \sigma^2)$ כאשר התוחלת ידועה
		שני הקודמים יחד	$X_1, \dots, X_n \sim N(\mu, \sigma^2)$
$H_0: \mu = \mu_0$ $H_1: \mu > \mu_0$ $\frac{X - \mu_0}{\sigma} \geq c$ כאן תלוי ב- $\mu$			$X \sim N(\mu, \sigma^2)$ דגימה בודדת
$H_0: \theta = \theta_0$ $H_1: \theta = \theta_1 > \theta_0$ $\sum_{i=1}^n X_i \geq c$		$\hat{\theta}(X) = \bar{X}$	$X_1, \dots, X_i \sim Pois(\theta)$

$A_2$  - לאבי יותר "עץ",  $A_3$  - לשניהם אותו מספר הטלות "עץ". נחשב את ההסתברויות של המאורעות:  
 $P(A_1) = P(A_2)$ ,  $P(A_3) = 1 - P(A_1) - P(A_2) = 1 - 2P(A_1)$   
 $P(B) = P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + P(B|A_3)P(A_3)$   
 $= 1 \cdot P(A_1) + 0 \cdot P(A_2) + \frac{1}{2} \cdot (1 - 2P(A_1)) = \frac{1}{2}$

**הגדרה:** פונקציית התפלגות (Probability Mass Function) או  $P_X(x)$  (Probability Distribution) של מ"מ  $X$  זו הפונקציה  
 $P(X = x) = \sum_{\omega \in \Omega, X(\omega)=x} P(\omega)$

**הגדרה:** ההסתברות לשרוד (Survival Function) על מ"מ  
 $P(X > s) = (1 - p)^{s+1}$  זוהי ההסתברות  $X \sim Geo(p)$

**טענה:** תכונת חוסר הזיכרון של מ"מ גיאומטרי: יהי  $Y \sim Geo(p)$   
אזי  $P(Y > s + t | Y \geq t) = P(Y > s)$

**טענה:** יהי  $X \sim Bin(p, n)$ . הגבול  $\lim_{n \rightarrow \infty} P(X = x)$  זהה להסתברות  $P(Y = x)$  עבור  $Y \sim Pois(np)$

**הגדרה:** יהי  $X$  מ"מ. התוחלת של  $X$  היא:  $E[X] = \sum_x P(X = x) \cdot x$

**טענה:** יהי  $X$  מ"מ ונגדיר  $Y = g(X)$  כאשר  $Y: \mathbb{R} \rightarrow \mathbb{R}$  פונקציה כלשהי. מתקיים:  $E[Y] = \sum_x g(x)P(X = x)$

- במצעים  $n$  הטלות ב"ת של מטבע עם הסתברות  $p$ . מהי ההסתברות שמספר ה"עץ" יהיה זוגי?
  - נגדיר מ"מ  $X \sim Bin(n, p)$  הסופר את מספר ה"עצים". נסמן  $P_n$  ההסתברות למס' זוגי של "עץ" לאחר  $n$  הטלות.  $P_0 = 1$ . נוסחת הנסיגה היא:  $P_n = P_{n-1}(1 - p) + (1 - P_{n-1})p = p + (1 - 2p)P_{n-1}$
  - $P_n = \frac{1}{2}(1 + (1 - 2p)^n)$ . באינדוקציה, נפתח ישירות.

**טענה:**  $P(\cup_{i=1}^n A_i) = P(A_1) + P(\bar{A}_1 \cap A_2) + \dots + P(\bar{A}_1 \cap \dots \cap \bar{A}_{n-1} \cap A_n)$

**הסתברות מותנית:**  $P(B|A) = \frac{P(A \cap B)}{P(A)}$

**טענה (חוק הכפל או חוק השרשרת):**  $P(\cap_{i=1}^n A_i) = P(A_1)P(A_2|A_1) \dots P(A_n|A_1 \cap \dots \cap A_{n-1})$

**טענה (נוסחת ההסתברות השלמה):** עבור זוג מאורעות  $A, B$  מתקיים  $P(B) = P(A)P(B|A) + P(\bar{A})P(B|\bar{A})$

**טענה (חוק בייס - Bayes):**  $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$

**בניסוח אחר:**  $P(A|B) = \frac{P(B|A)P(A)}{P(B|A)P(A) + P(B|\bar{A})P(\bar{A})}$

$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{P(B)} = \frac{P(B|A_i)P(A_i)}{\sum_{i=1}^n P(B|A_i)P(A_i)}$ : חלוקה:  $A_1, \dots, A_n$

**הגדרה:** אם  $P(A|B) = P(B)$  אז נאמר ש- $A$  בלתי-תלוי ב- $B$ . בניסוח אחר,  $P(A \cap B) = P(A)P(B)$ . נסמן  $A \perp B$

**טענה:**  $A \perp B \Rightarrow A \perp \bar{B}$

**הגדרה:** נאמר שהמאורעות  $A_1, \dots, A_n$  בלתי-תלויים אם לכל  $S \subseteq \{1, \dots, n\}$  מתקיים  $P(\cap_{i \in S} A_i) = \prod_{i \in S} P(A_i)$

- אבי מטיל  $n$  מטבעות ובתיה מטילה  $n + 1$  מטבעות (הוגנים, ב"ת). מהי הסיכוי שלבתיה יהיה יותר "עץ" מאשר לאבי?
  - נסמן  $B$  - לבתיה יש יותר "עץ" מלאבי. נסתכל על  $n$  ההטלות הראשונות שלהם ונסמן:  $A_1$  - לבתיה יותר "עץ",

$$P(X = x) = \sum_y P(X = x, Y = y)$$

$$= \sum_y P(Y = y)P(X = x|Y = y)$$

• משדר שולח 1 בהסתברות  $p$  ו-0 בהסתברות  $1-p$ , באופן ב"ת בשידורים קודמים. נגדיר  $Z$  - מספר השידורים ליחידת זמן, וידוע ש- $Z \sim Pois(\lambda)$ . מה ההתפלגות של ה-1 ימים ביחידת זמן?

○ נסמן ב- $X$  את מספר ה-1 ימים,  $Y$  מספר ה-0 ימים ונחשב את ההתפלגות המשותפת:

$$P(X = n, Y = m) = P(X = n, Y = m, Z = n + m)$$

$$= P(X = n, Y = m|Z = n + m)P(Z = n + m) =$$

$$= e^{-\lambda} \frac{\lambda^{n+m}}{(n+m)!} \binom{n+m}{n} p^n (1-p)^m$$

$$P(X = n) = \sum_{m=0}^{\infty} P(X = n, Y = m)$$

$$= \sum_{m=0}^{\infty} e^{-\lambda} \frac{\lambda^{n+m}}{(n+m)!} \binom{n+m}{n} p^n (1-p)^m$$

$$= \sum_{m=0}^{\infty} e^{-\lambda} \frac{\lambda^{n+m}}{n! m!} p^n (1-p)^m =$$

$$= \frac{(\lambda p)^n e^{-\lambda p}}{n!} \sum_{m=0}^{\infty} \frac{(1-p)^m e^{-\lambda(1-p)} \lambda^m}{m!}$$

$$= \frac{(\lambda p)^n e^{-\lambda p}}{n!} e^{-\lambda(1-p)} \sum_{m=0}^{\infty} \frac{(\lambda(1-p))^m}{m!} = \frac{(\lambda p)^n e^{-\lambda p}}{n!}$$

○ כאשר כאן המעבר האחרון היה לפי טיילור של  $e^x$  (במקרה הזה,  $x = \lambda(1-p)$ ). לבסוף קיבלנו ש- $X \sim Pois(\lambda p)$ , מה שדי סביר אינטואיטיבית.

**הגדרה:** יהיו  $X, Y$  מ"מ  $A$ -ו מאורע. התוחלת המותנית של  $X$  בהינתן  $Y$  או  $A$  מוגדרת להיות:

$$E[X|Y = y] = \sum_x xP(X = x|Y = y)$$

$$E[X|A] = \sum_x xP(X = x|A)$$

**טענה (נוסחת התוחלת השלמה עבור מאורעות):** תהי  $A_1, \dots, A_n$  חלוקה של  $\Omega$ . אזי  $E_i[E_X[X|A_i]] = E[X]$

**טענה (נוסחת התוחלת השלמה עבור משתנים מקריים):** יהיו  $X, Y$  מ"מ. אזי  $E_Y[E_X[X|Y]] = E[X]$

**טענה:**  $E[XY]^2 \leq E[X^2]E[Y^2]$

**טענה:** לכל  $g(x, y)$ ,  $E[g(X, Y)|Y] = \sum_x g(x, Y)P_{X|Y}(x)$

**טענה:** לכל  $X, Y, Z$  מתקיים  $E[E[X|Y, Z]|Z] = E[X|Z]$

**הגדרה:** מ"מ  $X, Y$  ייקראו בלתי-תלויים אם לכל  $x, y$  מתקיים  $P(X = x, Y = y) = P(X = x)P(Y = y)$

**הגדרה:** יהיו  $X, Y, Z$  מ"מ.  $X, Y$  ייקראו בלתי-תלויים בהינתן  $Z$  אם לכל  $x, y, z$  מתקיים  $P(X = x, Y = y|Z = z) = P(X = x|Z = z)P(Y = y|Z = z)$

$$P_n = \frac{1}{2} \left[ \sum_{i=0}^n \binom{n}{i} p^i (1-p)^{n-i} + \sum_{i=0}^n (-1)^i \binom{n}{i} p^i (1-p)^{n-i} \right]$$

$$= \frac{1}{2} \left[ 1 + \sum_{i=0}^n \binom{n}{i} (-p)^i (1-p)^{n-i} \right] =$$

$$= \frac{1}{2} [1 + (-p + (1-p))^n] = \frac{1}{2} (1 + (1-2p)^n)$$

**טענה:** יהי  $X$  מ"מ אי-שלילי, אזי  $E[X] = \sum_{x=0}^{\infty} P(X > x)$

**טענה (ליניאריות התוחלת):**  $E[aX + b] = aE[X] + b$ , מ"מ  $X$

**הגדרה:** השונות של מ"מ  $X$   $Var(X) := E[(X - E[X])^2]$   
**טעיית התקן של  $X$**  היא  $Std(X) = \sqrt{Var(X)}$

**הגדרה:** המומנט ה- $k$  של מ"מ  $X$  הוא  $E[X^k]$

**טענה:**  $Var(X) = E[X^2] - E[X]^2$

**טענה:**  $Var(aX + b) = a^2 Var(X)$ , מ"מ  $X$

**הגדרה:**  $X, Y$  מ"מ. ההתפלגות המשותפת:  $P(X = x, Y = y) = P_X(x) \cap \{Y = y\}$   
 $P_X(x) = \sum_y P_{X,Y}(x, y)$

**טענה (ליניאריות התוחלת):** יהיו  $X, Y$  משתנים מקריים, אזי  $E[X + Y] = E[X] + E[Y]$

מטילים קוביה עם  $k$  פאות, כשלפאה ה- $i$  הסתברות  $p_i$ . יהי  $X_i$  מספר הפעמים שיצאה הפאה ה- $i$  ב- $N$  הטלות. ה- $k-1$  ערכים הראשונים קובעים את הערך האחרון. זו התפלגות מולטינומית:

$$P_{X_1, \dots, X_k}(n_1, \dots, n_k) = \binom{N}{n_1, n_2, \dots, n_k} p_1^{n_1} p_2^{n_2} \dots p_k^{n_k}$$

$$= \frac{N!}{n_1! n_2! \dots n_k!} p_1^{n_1} p_2^{n_2} \dots p_k^{n_k}$$

ההתפלגות השולית של משתנה מסוים.

$$P_{X_i}(n_i) = \sum_{n_1, \dots, n_{i-1}, n_{i+1}, \dots, n_k} P_{X_1, \dots, X_k}(n_1, \dots, n_k)$$

על כל משתנה אפשר לחשוב כהצלחה/כישלון בבחירת  $i$ .  $X_i \sim Bin(N, p_i)$

**הגדרה:** יהי  $X$  מ"מ  $A$ -ו מאורע, נגדיר ההתפלגות המותנית של  $X$  בהינתן המאורע  $A$ .  $P_{X|A}(x) = P(X = x|A) := \frac{P(\{X=x\} \cap A)}{P(A)}$

**הגדרה:** יהיו  $X, Y$  מ"מ, נגדיר ההתפלגות המותנית של  $X$  בהינתן  $Y$ .  $P_{X|Y}(x, y) = P(X = x|Y = y) = \frac{P(\{X=x\} \cap \{Y=y\})}{P(Y=y)} = \frac{P_{X,Y}(x, y)}{P(Y=y)}$

**בניסוח אחר.**  $P(X = x, Y = y) = P(Y = y)P(X = x|Y = y)$ . שזהו חוק הכפל (או חוק השרשרת) עבור משתנים מקריים. באופן דומה אפשר לקבל גם את נוסחת ההסתברות השלמה:

**טענה:**  $Var(X + Y) = Var(X) + Var(Y)$  אזי  $X, Y$  מ"מ ב"ת. אזי

- $n$  סניפים רוצים להתאחד. בכל סניף  $i$  מס' הלקוחות היומי  $X_i$  מתפלג פואסון עם פרמטר  $\lambda_i$  באופן ב"ת. מספר הלקוחות בסניף המאוחד, שנסמנו  $X$ :
  - התוחלת:  $E[X] = \sum_{i=1}^n E[X_i] = \sum_{i=1}^n \lambda_i$
  - נפתח את פונקציית ההתפלגות לסניף המאוחד – לצורך הנוחות נסתכל כרגע על  $n = 2$ :
 
$$P(X = x) = P(X_1 + X_2 = x) = P(\{X_1 = 0\} \cap \{X_2 = x\}) \cup \dots \cup (\{X_1 = x\} \cap \{X_2 = 0\}) = \sum_{m=0}^x P(X_1 = m)P(X_2 = x - m) = \sum_{m=0}^x e^{-\lambda_1} \frac{\lambda_1^m}{m!} e^{-\lambda_2} \frac{\lambda_2^{x-m}}{(x-m)!} = \frac{1}{x!} e^{-(\lambda_1 + \lambda_2)} \sum_{m=0}^x \frac{x!}{m!(x-m)!} \lambda_1^m \lambda_2^{x-m} = \frac{1}{x!} e^{-(\lambda_1 + \lambda_2)} (\lambda_1 + \lambda_2)^x$$
    - כלומר, קיבלנו ש- $X \sim Pois(\lambda_1 + \lambda_2)$
    - כעת, בהינתן  $X = s$ , מהי התפלגות  $X_i$ ? בה"כ  $i = 1$  וזאז:
 
$$P(X_1 = x | X = s) = \frac{P(X_1 = x, X = s)}{P(X = s)} = \frac{P(X_1 = x, X_2 + \dots + X_n = s - x)}{P(X = s)} = \frac{e^{-\lambda_1} \frac{\lambda_1^x}{x!} e^{-(\lambda_2 + \dots + \lambda_n)} (\lambda_2 + \dots + \lambda_n)^{s-x}}{e^{-(\lambda_1 + \dots + \lambda_n)} (\lambda_1 + \dots + \lambda_n)^s} = \frac{s!}{x!(s-x)!} \lambda_1^x (\lambda_2 + \dots + \lambda_n)^{s-x} = \binom{s}{x} \left( \frac{\lambda_1}{\sum_{i=1}^n \lambda_i} \right)^x \left( \frac{\sum_{i=2}^n \lambda_i}{\sum_{i=1}^n \lambda_i} \right)^{s-x}$$
      - וכעת אם נסמן  $p = \frac{\lambda_1}{\sum_{i=1}^n \lambda_i}$ , אז מקבלים ש- $X_1 | X = s \sim Bin(s, p)$

**הגדרה:** מ"מ רציף הוא פונקציה  $X: \Omega \rightarrow \mathbb{R}$ , כך שקיימת פונקציה צפיפות הסתברות, והמקיימת את האקסיומות הבאות:

$$(1) f_X(x) \geq 0 \text{ לכל } x$$

$$(2) \int_{-\infty}^{\infty} f_X(x) dx = 1$$

**הגדרה:** אם  $X$  מ"מ רציף ו- $f_X$  פונקציית הצפיפות שלו, התוחלת שלו היא:  $E[X] := \int_{-\infty}^{\infty} x f_X(x) dx$

לכל פונקציה של מ"מ  $g: \mathbb{R} \rightarrow \mathbb{R}$ ,

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

**הגדרה:** אם  $X$  מ"מ רציף ו- $f_X$  פונקציית הצפיפות שלו, השונות שלו היא:  $Var(X) := \int_{-\infty}^{\infty} (x - E[X])^2 f_X(x) dx$

**טענה (תכונת חוסר הזיכרון):** יהי  $X \sim \exp(\lambda)$ , אזי  $P(X > t + s | X > s) = P(X > t)$

**הגדרה:** יהי  $X$  מ"מ עם פ' צפיפות  $f_X(x)$ , לפונקציה הבאה נקרא פונקציית ההתפלגות המצטברת של  $X$ :  $F_X(x) = \int_{-\infty}^x f_X(t) dt$  כמו כן,  $P(X \leq x) = \int_{-\infty}^x f_X(t) dt$

יהי  $Y$  מ"מ שהוא ההסתברות שהשמש זורחת מחר (אחיד, עם תומך  $\{0, \frac{1}{n}, \dots, \frac{n-1}{n}, 1\}$ )  $X \sim Bin(100, Y)$  ומתקיים  $E[X|Y] = 100Y$  (תוחלת של מ"מ הקרובים אז: בינומי).

כעת אפשר להשתמש בנוסחת התוחלת השלמה ולקבל:  $E[X] = E[E[X|Y]] = \sum_{i=0}^n P(Y = \frac{i}{n}) E[X|Y = \frac{i}{n}] = \frac{1}{n+1} \sum_{i=0}^n \frac{100i}{n}$

מטילים מטבע עם הסתברות  $p$  לעץ עד לקבלת עץ בפעם הראשונה. לאחר מכן מטילים שוב את אותו מספר הטלות וסופרים כמה עץ יצא. מה ההסתברות שלא יצא עץ בכלל בסיבוב השני?

- נסמן  $X$  – מספר ההטלות בסיבוב הראשון,  $X \sim Geo(p)$ . נסמן גם  $Y$  – מספר ההטלות בסיבוב השני, וכאן יש תלות בין המשתנים:  $Y|X = x \sim Bin(x, p)$ , כלומר  $Y, X \sim Bin(x, p)$ . כעת אנו מחשבים את  $P(Y = 0)$

$$P(Y = 0) = \sum_{x=1}^{\infty} P(Y = 0, X = x) = \sum_{x=1}^{\infty} P(Y = 0 | X = x) P(X = x) = \sum_{x=1}^{\infty} (1-p)^x p (1-p)^{x-1} = \frac{1-p}{2-p}$$

יהיו  $X_1 \sim Geo(p_1), X_2 \sim Geo(p_2)$  אזי  $\min\{X_1, X_2\} \sim Geo(1 - (1-p_1)(1-p_2))$

**הגדרה:** יהיו  $X_1, \dots, X_n$  מ"מ. הם ייקראו בלתי-תלויים אם  $P_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n P_{X_i}(x_i)$

**טענה:** אי-תלות בשלוש גוררת אי-תלות בזוגות.

נתון  $n \geq 3$  מספר טבעי. בשלב 1 מגרילים  $K$  מתוך  $\{1, 2, \dots, n\}$  בהסתברות לאו דווקא אחידה, אבל יודעים את  $\mu = E[K]$ . בשלב 2, דוגמים מתוך  $\{1, 2, \dots, n\}$  איברים ללא החזרה בהסתברות אחידה, ונסמנם  $S$ . נסמן גם  $X$  – מספר האיברים ב- $S$  שהם ב- $\{1, 2, 3\}$ .

- נמצא את התוחלת של  $X$ : בהינתן  $K$ , נסמן  $X_i$  (עבור  $i \in \{1, \dots, K\}$ ) מ"מ המקבל 1 אם המספר  $i$ -י שנבחר הוא ב- $\{1, 2, 3\}$  ו-0 אחרת. מתקיים  $X_i | K = k \sim Bin(k, \frac{1}{n})$  וכן  $E[X_i | K] = \frac{3}{n}$  (משתנה בינומי עם פרמטר  $\frac{3}{n}$ ).

$$E[X] = E[E[X|K]] = E\left[E\left[\sum_{i=1}^K X_i | K\right]\right] = E[KE[X_i]] = E\left[K \frac{3}{n}\right] = \frac{3\mu}{n}$$

- נמצא את ההתפלגות של  $X$ . יש שני סוגים של איברים  $\{1, 2, 3\}$  וכל השאר, מוציאים  $K$  איברים ושואלים מה ההסתברות ש- $X$  מתוכם הם מהסוג הראשון. כלומר,  $X \sim HG(K, 3, n-3)$ .
- מטילים מטבע שהסתברותו היא  $p$ , עד שמתקבל רצף של  $r > 0$  עצים. נסמן  $X$  את מספר ההטלות,  $Y$  מספר הטלות עד שהתקבל פלי (לראשונה). כמובן,  $Y \sim Geo(1-p)$ .

$$E[X] = E[E[X|Y]] = \sum_{y=1}^{\infty} P(Y = y) E[X|Y = y] = (*)$$

על התוחלת המותנית אנו יכולים לומר את הדבר הבא:

$$E[X|Y = y] = \begin{cases} r & y > r \\ y + E[X] & y \leq r \end{cases}$$

זאת משום שאם  $y \leq r$ , אז  $y$  ניסיונות כבר קרו, ועכשיו שוב ממשיכים עם  $X$  כאילו שחזרנו להתחלה. לכן:

$$(*) = \sum_{y=1}^r (y + E[X])(1-p)p^{y-1} + \sum_{y=r+1}^{\infty} r(1-p)p^{y-1} = \frac{1-p^r}{1-p} + (1-p^r)E[X] \Rightarrow E[X] = \frac{1-p^r}{p^r(1-p)}$$

כך נוכל לחשב גם את השונות, שכן  $E[X^2|Y = y] = \begin{cases} r^2 & y > r \\ E[(y+X)^2] & y \leq r \end{cases}$

**טענה:**  $X, Y$  מ"מ ב"ת. אזי  $E[XY] = E[X]E[Y]$

**טענה:** (טריק שימושי)  $E[XY] = E[E[XY|Y]] = E[YE[X|Y]]$

**טענה:** אם  $A = \{X \in \Gamma\}$  עבור  $\Gamma$  קטע כלשהו, אזי  $f_{X|A}(x) =$

$$\begin{cases} \frac{f_X(x)}{P(X \in \Gamma)} & x \in \Gamma \\ 0 & x \notin \Gamma \end{cases}$$

**הגדרה:** יהיו  $X, Y$  מ"מ רציפים, ההסתברות של  $X$  בהינתן  $Y$  מוגדרת להיות:  $P(X \in \Gamma | Y = y) = \lim_{\epsilon \rightarrow 0^+} \frac{P(X \in \Gamma, |Y - y| \leq \epsilon)}{P(|Y - y| \leq \epsilon)}$

• שוברים מקל באורך  $L$  באופן מקרי ואחיד בנקודה מסוימת, נסמן  $Y$  אורך המקל שנותר. כעת שוברים את המקל שנוותר שוב באופן מקרי ואחיד, ונסמן  $X$  אורך המקל הסופי. רוצים למצוא את הצפיפות המשותפת  $f_{X,Y}$ .

○ ראשית נשים לב ש- $Y \sim U(0, L)$ , כלומר  $f_Y(y) = \frac{1}{L}$ . לכן  $E[Y] = \frac{L}{2}$  וגם  $F_Y(y) = \frac{y}{L}$

○ כמו כן,  $X|Y \sim U(0, Y)$ . כעת מהגדרת צפיפות מותנית אנו יכולים למצוא את הצפיפות המשותפת:

$$f_{X|Y}(x, y) = \frac{f_{X,Y}(x, y)}{f_Y(y)} \Rightarrow f_{X,Y}(x, y) = f_{X|Y}(x, y) f_Y(y)$$

$$= \begin{cases} \frac{1}{Ly} & 0 \leq x \leq y \leq L \\ 0 & \text{otherwise} \end{cases}$$

○ כעת אפשר למצוא את ההסתברות השולית של  $X$ :

$$f_X(x) = \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy = \int_x^L \frac{1}{Ly} dy = \frac{1}{L} [\log(y)]_x^L$$

$$= \begin{cases} \frac{1}{L} (\log L - \log x) & 0 \leq x \leq L \\ 0 & \text{otherwise} \end{cases}$$

○ וכעת אפשר לחשב את התוחלת של  $X$ , נשתמש לשם כך שתוחלת מותנית:

$$E[X|Y = y] = \int_{-\infty}^{\infty} x f_{X|Y}(x, y) dx = \frac{y}{2} \Rightarrow E[X|Y] = \frac{Y}{2} \Rightarrow E[E[X|Y]]$$

$$= E\left[\frac{Y}{2}\right] = \frac{1}{2} E[Y] = \frac{L}{4}$$

○ באופן דומה אפשר לחשב את  $E[XY] = E[E[XY|Y]] = E\left[\frac{Y^2}{2}\right]$  וגם את השונות המותנית.

**טענה (חוק בייס הרציף):** יהיו  $X, Y$  מ"מ רציפים, אזי

$$f_{X|Y}(u, v) = \frac{f_{Y|X}(v, u) f_X(u)}{f_Y(v)}$$

בגרסה אחרת, אפשר לכתוב במפורש את ההתפלגות השולית

של  $Y$  ולקבל:  $f_{X|Y}(u, v) = \frac{f_{Y|X}(v, u) f_X(u)}{\int_{-\infty}^{\infty} f_{Y|X}(v, t) f_X(t) dt}$

• לנורה יש אורך חיים אקספוננציאלי עם פרמטר  $\lambda$ , כאשר  $\Lambda \sim U(1, 1.5)$  בוחנים את המנורה ומודדים אורך חיים  $y$ ; מה ניתן לומר עכשיו על  $\Lambda$ ?

○ נתחיל במציאת הצפיפות המותנית:

$$f_{\Lambda|Y}(\lambda, y) = \frac{f_{Y|\Lambda}(y, \lambda) f_{\Lambda}(\lambda)}{f_Y(y)} = \frac{2\lambda e^{-\lambda y}}{f_Y(y)} = \frac{\lambda}{e^{\lambda y}} C$$

○ כעת אפשר למצוא את המקסימום של הפונקציה כדי לראות מה ה- $\lambda$  הסביר ביותר בהינתן  $y$  שקיבלנו מהמדידה:

$$\frac{d}{d\lambda} f_{\Lambda|Y}(\lambda, y) = c [e^{-\lambda y} + \lambda e^{-\lambda y} (-y)] = 0 \Leftrightarrow ce^{-\lambda y} [1 + \lambda y] = 0 \Leftrightarrow \lambda = \frac{1}{y}$$

**טענה (כלל בייס המעורב):** יהיו  $X$  מ"מ בדיד,  $Y$  מ"מ רציף, אזי

מתקיים:  $P_{X|Y}(x, y) = \frac{f_{Y|X}(y, x) P(X=x)}{f_Y(y)}$

**הערה:** אפשר לכתוב את המכנה בעזרת נוסחת הסתברות שלמה:  $f_Y(y) = \sum_k f_{Y|X}(y, k) P(X=k)$ , כדי להימנע מהצורך לחשב ישירות את הצפיפות השולית.

$$P(a \leq X \leq b) = F_X(b) - F_X(a) = \int_a^b f_X(x) dx \quad (1)$$

$$F_X(x) \text{ לא יורדת} \quad (2)$$

$$\lim_{x \rightarrow -\infty} F_X(x) = 0 \text{ מתקיים} \quad (3)$$

$$\lim_{x \rightarrow \infty} F_X(x) = 1 \text{ מתקיים} \quad (4)$$

$$\lim_{\epsilon \rightarrow 0^+} F_X(x + \epsilon) = F_X(x) \text{ רציפה מימין.} \quad (5)$$

• לכל קבוצת מ"מ ב"ת  $X = \max\{X_1, \dots, X_n\}$  מתקיים:

$$F_X(x) = F_{X_1}(x) \cdots F_{X_n}(x)$$

•  $X_1, \dots, X_n$  מ"מ רציפים ב"ת ש"ה עם פ' צפיפות  $f_X(x)$ .

○ אם  $Y = \max\{X_1, \dots, X_n\}$  אז  $F_Y(y) = (F_X(y))^n$

○ אם  $Y = \min\{X_1, \dots, X_n\}$  אז  $F_Y(y) = 1 - (1 - F_X(y))^n$ .

• יהיו  $X_i \sim \exp(\lambda_i)$  מ"מ ב"ת, אזי  $\min\{X_1, \dots, X_n\} \sim \exp(\sum_{i=1}^n \lambda_i)$

**טענה:** יהי  $X$  מ"מ רציף אי-שלילי, אזי  $E[X] = \int_0^{\infty} P(X > x) dx$

**הגדרה:**  $Z \sim N(0, 1)$  נקרא נורמלי סטנדרטי, וה-CDF שלו מסומנת  $\Phi(z)$ . עבור  $0 \leq \alpha \leq 1$  נסמן  $z_\alpha$  הערך עבורו  $P(Z \leq z_\alpha) = \alpha$ .

**טענה:** אם  $Z \sim N(0, 1)$  אז  $aZ + b \sim N(b, a^2)$

**הגדרה:** מ"מ  $X, Y$  נקראים רציפים במשותף אם לכל  $D \subseteq \mathbb{R}^2$

מתקיים:  $P((x, y) \in D) = \iint_D f_{X,Y}(u, v) dudv$ , כאשר  $f_{X,Y}$  נקראת פונקציית הצפיפות המשותפת שלהם.

**פונקציית הצפיפות המשותפת מקיימת את התכונות הבאות:**

$$(1) \text{ לכל } u, v \text{ מתקיים } f_{X,Y}(u, v) \geq 0$$

$$(2) \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{X,Y}(u, v) du dv = 1 \text{ מתקיים}$$

**הגדרה:** פונקציית הצפיפות השולית של  $X$  אם  $X, Y$  רציפים

$$\text{במשותף היא } f_X(u) = \int_{-\infty}^{\infty} f_{X,Y}(u, v) dv$$

**הגדרה:**  $(X, Y)$  מ"מ. הפונקציה  $F_{X,Y}(u, v) = P(X \leq u, Y \leq v)$  נקראת פונקציית הצטברות משותפת.

כאשר  $(X, Y)$  רציפים במשותף, מתקיים  $F_{X,Y}(u, v) = \int_{-\infty}^u \int_{-\infty}^v f_{X,Y}(s, t) ds dt$ .

כאשר המ"מ בדידים, מתקיים  $F_{X,Y}(u, v) = \sum_{x \leq u} \sum_{y \leq v} P_{X,Y}(x, y)$ . עובד גם על מעורבים.

**הגדרה:** יהיו  $X, Y$  מ"מ רציפים במשותף ו- $g: \mathbb{R}^2 \rightarrow \mathbb{R}$ , אז

$$E[g(X, Y)] = \iint_{\mathbb{R}^2} g(u, v) f_{X,Y}(u, v) dudv$$

**הגדרה:** יהי  $X$  מ"מ רציף ו- $A$  מאורע. פונקציית התפלגות מצטברת מותנית של  $X$  בהינתן המאורע  $A$  מוגדרת להיות

$F_{X|A}(u) = P(X \leq u | A)$  ופונקציית הצפיפות המותנית מוגדרת להיות

$$f_{X|A}(u) = \frac{d}{du} F_{X|A}(u)$$

כעת מתקיים  $P(X \in \Gamma | A) = \int_{\Gamma} f_{X|A}(u) du$ , לכל  $\Gamma \subseteq \mathbb{R}$ .

**טענה (נוסחת ההסתברות השלמה):** אם  $A_1, \dots, A_n$  חלוקה של  $\Omega$ , אזי  $f_X(x) = \sum_{i=1}^n P(A_i) f_{X|A_i}(x)$ .

**טענה (נוסחת השונות השלמה):** יהיו  $X, Y$  מ"מ. אזי  $Var(Y) = E[Var(Y|X)] + Var(E[Y|X])$

יהיו  $X$  מ"מ,  $Y = g(X)$ , ונתונה  $f_X(x)$ . רוצים למצוא את  $f_Y(y)$  וכל מה שנובע מזה. כדי לעשות זאת, נעבור דרך ההתפלגות המצטברת:  $F_Y(y) = P(Y \leq y) = P(g(X) \leq y) = \int_{x: g(x) \leq y} f_X(x) dx$ . במקרים מסוימים, זה יהיה מספיק פשוט כדי שנוכל לחשבו, לגזור את התוצאה ולהגיע ל- $f_Y(y)$ .

• יהיו  $X \sim U(-1, 1)$  ו- $Y = \sqrt{|X|}$ . הטרנספורמציה הזאת אינה מונוטונית ולכן נצטרך למצוא את מבוקשנו ידנית:

$$f_Y(y) = \frac{d}{dy} F_Y(y) = \frac{d}{dy} P(Y \leq y) = \frac{d}{dy} P(\sqrt{|X|} \leq y)$$

$$= \frac{d}{dy} P(|X| \leq y^2) = \frac{d}{dy} P(-y^2 \leq X \leq y^2)$$

$$= \frac{d}{dy} \frac{2y^2}{2} = 2y$$

**טענה:** יהי  $X$  מ"מ,  $Y = g(X)$  כאשר  $g$  מונוטונית ממש. אזי  $f_Y(y) = f_X(g^{-1}(y)) \left| \frac{d}{dy} g^{-1}(y) \right|$

• 2 חברים קובעים להיפגש. כל אחד מאחר באופן ב"ת בזמן אקספוננציאלי עם פרמטר  $\lambda$ . מה הצפיפות של הפרש הזמנים בהם הם מגיעים?  
 ◦ נסמן  $X, Y$  זמני ההגעה ו- $Z = X - Y$  ההפרש המבוקש. נתחיל מהמקרה שההפרש חיובי:

$$F_Z(z) = P(X - Y \leq z) = 1 - P(X - Y \geq z)$$

$$= 1 - \int_0^\infty \int_{z+y}^\infty f_{X,Y}(x, y) dx dy$$

$$= 1 - \int_0^\infty f_Y(y) \int_{z+y}^\infty f_X(x) dx dy =$$

$$= 1 - \int_0^\infty \lambda e^{-\lambda y} \int_{z+y}^\infty \lambda e^{-\lambda x} dx dy = 1 - \int_0^\infty \lambda e^{-\lambda y} [-e^{-\lambda x}]_{z+y}^\infty dy$$

$$= 1 - \int_0^\infty \lambda e^{-\lambda y} e^{-\lambda(z+y)} dy =$$

$$= 1 - e^{-\lambda z} \int_0^\infty \lambda e^{-2\lambda y} dy = 1 - e^{-\lambda z} \cdot \frac{1}{2}$$

$$f_Z(z) = \frac{d}{dz} \left( 1 - e^{-\lambda z} \cdot \frac{1}{2} \right) = \frac{\lambda}{2} e^{-\lambda z}$$

◦ במקרה שההפרש שלילי, אפשר לראות משיקולי סימטריה שמקבלים:

$$F_Z(z) = P(Z \leq z) = P(-Z \geq -z) = P(Z \geq -z) = 1 - F_Z(-z)$$

$$= 1 - \left( 1 - \frac{e^{\lambda z}}{2} \right) = \frac{e^{\lambda z}}{2}$$

$$f_Z(z) = \frac{d}{dz} \frac{e^{\lambda z}}{2} = \frac{\lambda}{2} e^{\lambda z}$$

◦ זאת משום של- $(X - Y)$  ול- $(Y - X)$  צריכה להיות אותה התפלגות - סימטריה מוחלטת בין המ"מ.

**הגדרה: השונות המשותפת (Covariance)** של מ"מ  $X, Y$  היא:  $Cov(X, Y) = E[(X - E[X])(Y - E[Y])]$

**הגדרה:** נקראים בלתי-מתואמים אם  $Cov(X, Y) = 0$

**נשים לב שמתקיים:**  $Cov(X, X) = E[(X - E[X])(X - E[X])] = Var(X)$   
 $Cov(X, Y) = E[XY] - E[X]E[Y]$  וכן  $E[X]E[Y]$

**טענה:** יהיו  $X, Y$  מ"מ ב"ת. אזי  $Cov(X, Y) = 0$

ההיפך לא נכון: ייתכנו מ"מ בלתי-מתואמים שאינם בלתי-תלויים.

**טענה:**  $Cov(X + Y, Z) = Cov(X, Z) + Cov(Y, Z)$

**טענה (כלל בייס המעורב, 2):** יהיו  $X$  מ"מ בדיד,  $Y$  מ"מ רציף, אז מתקיים:  $f_{Y|X}(y, x) = \frac{P_{X|Y}(x, y) f_Y(y)}{\int_{-\infty}^{\infty} P_{X|Y}(x, t) f_Y(t) dt}$

במכנה מופיעה, למעשה, ההסתברות השולית  $P_X(x)$ .

**הגדרה:** תוחלת מותנית של מ"מ רציפים  $X, Y$  מוגדרת ע"י  $E[X|Y = y] = \int_{-\infty}^{\infty} x f_{X|Y}(x, y) dx$

**הגדרה:** מ"מ רציפים  $X, Y$  נקראים בלתי-תלויים אם  $f_{X,Y}(x, y) = f_X(x) f_Y(y)$

מהגדרה זו אפשר לקבל גם הסתברות משותפת:

$$P(X \in A, Y \in B) = \int_A \int_B f_{X,Y}(x, y) dy dx$$

$$= \int_A \int_B f_X(x) f_Y(y) dy dx$$

$$= \int_A f_X(x) dx \int_B f_Y(y) dy =$$

$$= \left( \int_A f_X(x) dx \right) \left( \int_B f_Y(y) dy \right)$$

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

ולכן האי-תלות שקולה בהגדרה גם לגבי התפלגות מצטברת משותפת:  $F_{X,Y}(x, y) = F_X(x) F_Y(y)$

**טענה:** מ"מ  $X, Y$  הם בלתי-תלויים אםם לכל זוג פונקציות  $\varphi, \psi$  מתקיים  $E[\varphi(X)\psi(Y)] = E[\varphi(X)]E[\psi(Y)]$

**טענה:**  $X, Y$  ב"ת  $Z = X + Y$  ו- $f_Z(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z - x) dx$

• בהתקפת קניות שולה מבקרת במספר מקרי  $N$  של חנויות, ובחנות ה- $i$  מבזזת סכום מקרי  $X_i$ . נניח ש- $N$  הוא שלם חיובי עם פונקציית התפלגות ידועה ו- $X_i$  כולם בעלי אותה תוחלת  $\mu$  ושונות  $\sigma^2$ , וכל המ"מ בשאלה ב"ת. מהי תוחלת ושונות עלות מסע הקניות?

◦ נסמן ב- $T$  את סך הכסף ששולה הוציאה,  $T = \sum_{i=1}^N X_i$ . כאן מתקיים:

$$E[T|N = n] = E\left[\sum_{i=1}^n X_i \mid N = n\right] = \sum_{i=1}^n E[X_i|N = n] = \sum_{i=1}^n E[X_i] = n\mu$$

$$E[T] = E[E[T|N]] = E[n\mu] = \mu E[N]$$

$$E[T^2] = \sum_{n=1}^{\infty} P(N = n) E[T^2|N = n]$$

$$= \sum_{n=1}^{\infty} P(N = n) E[(X_1 + \dots + X_n)^2 | N = n] =$$

$$= \sum_{n=1}^{\infty} P(N = n) E[nX_1^2 + n(n-1)X_1X_2]$$

◦ המעבר הזה נכון כיוון שהמ"מ כולם אותו דבר, ויש לנו רק שני סוגים שונים של גורמים - ריבועים של אותו מ"מ, ומכפלות של שני מ"מ שונים. בשני המקרים תוחלות שונות כי  $X_i, X_j$  כאן ב"ת אם  $i \neq j$ . אפשר להמשיך מכאן:

$$= \sum_{n=1}^{\infty} P(N = n) [E[nX_1^2|N = n] + E[n(n-1)X_1X_2|N = n]]$$

$$= \sum_{n=1}^{\infty} P(N = n) (n\sigma^2 + n(n-1)\mu^2)$$

**טענה:** יהיו  $X \sim N(\mu_X, \sigma_X^2), Y \sim N(\mu_Y, \sigma_Y^2)$  ב"ת, ו- $Z = X + Y$  אזי  $Z \sim N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2)$

**טענה:**  $Var(X + Y) = Var(X) + Var(Y) + 2Cov(X, Y)$  ובאופן כללי:  
 $Var(\sum_{i=1}^n X_i) = \sum_{i=1}^n Var(X_i) + \sum_{i \neq j} Cov(X_i, X_j)$

**הגדרה:** תהי  $(X_n)_{n=1}^\infty$  סדרת מ"מ. נאמר שהסדרה  $(X_n)$  מתכנסת בהסתברות ל- $X$  אם לכל  $\varepsilon > 0$   $\lim_{n \rightarrow \infty} P(|X_n - X| \geq \varepsilon) = 0$

**טענה:**  $Var(X)Var(Y) \geq Cov^2(X, Y)$

**הגדרה:** יהיו  $X, Y$  מ"מ. מקדם המתאם שלהם מוגדר להיות  $\rho(X, Y) = \frac{Cov(X, Y)}{\sqrt{Var(X)Var(Y)}}$  מקדם המתאם מקיים:

$-1 \leq \rho(X, Y) \leq 1$  (1)

$X = aY + b \Leftrightarrow |\rho(X, Y)| = 1$  (2)

(3) חסר יחידות (היחידות של המונה והמכנה מתבטלות)

**טענה (אי-שוויון מרקוב):**  $X$  מ"מ אי-שלילי. אזי  $P(X \geq c) \leq \frac{E[X]}{c}$

**טענה (אי-שוויון צ'בישב):**  $X$  מ"מ עם תוחלת  $\mu$  ושונות  $\sigma^2$ . אזי  $P(|X - \mu| \geq c) \leq \frac{\sigma^2}{c^2}$

**מסקנה:**  $P(|X - \mu| \geq k\sigma) \leq \frac{\sigma^2}{(k\sigma)^2} = \frac{1}{k^2}$

• יהיו  $X \sim U(0,1), Y \sim U(0,1)$  נגדיר  $T = Y - X$ . נמצא את הצפיפות של  $T$ . לשם כך נצטרך לחשב אינטגרל:  $P(T \leq t) = P(Y - X \leq t) = \iint f_{X,Y}(x, y) dy dx$  קבוצת הנקודות שעבורן  $y \leq t + x$ . את זה נצטרך לעשות בשני אזורים שונים:

עבור  $-1 \leq t \leq 0$ :

$$\int_{-t}^0 \int_0^{t+x} f_{X,Y}(x, y) dy dx = \int_{-t}^0 \int_0^{t+x} f_X(x) f_Y(y) dy dx = \int_{-t}^0 \int_0^{t+x} 1 dy dx = \frac{t^2}{2} + t$$

עבור  $0 \leq t \leq 1$  נעדיף לחשב את השטח של המשולש מעל האזור שמעניין אותנו:

$$1 - P(Y - X \geq t) = 1 - \int_0^{1-t} \int_{t+x}^1 dy dx = t - \frac{t^2}{2} + \frac{1}{2}$$

את מה שקיבלנו אפשר עכשיו לגזור:  $f_T(t) = \begin{cases} 1+t & -1 \leq t \leq 0 \\ 1-t & 0 \leq t \leq 1 \end{cases}$

**משפט (החוק החלש של המספרים הגדולים):** תהי סדרה של מ"מ ב"ת שווי התפלגות עם תוחלת  $\mu$ . אזי הסדרה  $(\frac{X_1 + \dots + X_n}{n})$  מתכנסת בהסתברות ל- $\mu$ .

**הגדרה:** סדרה  $(X_n)$  של מ"מ מתכנסת בהתפלגות למ"מ  $X$  אם  $\lim_{n \rightarrow \infty} F_{X_n} = F_X$  (שוויון פונקציות).

• יהיו  $X_i \sim U(0,1)$  ב"ת ש"ה, ו- $Y_n = \min\{X_1, \dots, X_n\}$ . נראה ש- $Y_n \xrightarrow{p} 0$  (מתכנסת בהסתברות ל-0).  $P(|Y_n - 0| \geq \varepsilon) = P(\min\{X_1, \dots, X_n\} \geq \varepsilon) = P(X_1 \geq \varepsilon, \dots, X_n \geq \varepsilon)$

$$= \prod_{i=1}^n P(X_i \geq \varepsilon) = (1 - \varepsilon)^n \xrightarrow{n \rightarrow \infty} 0$$

נגדיר  $W_n = nY_n$ . סדרה זו לא מתכנסת בהסתברות ל-0:

$$1 - F_{W_n}(\varepsilon) = P(W_n \geq \varepsilon) = P(nY_n \geq \varepsilon) = P(\min\{X_1, \dots, X_n\} \geq \frac{\varepsilon}{n})$$

$$= \left(1 - F_{X_i}\left(\frac{\varepsilon}{n}\right)\right)^n = \left(1 - \frac{\varepsilon}{n}\right)^n \xrightarrow{n \rightarrow \infty} e^{-\varepsilon}$$

קיבלנו ש- $1 - e^{-\varepsilon} \xrightarrow{n \rightarrow \infty} 1 - e^{-\varepsilon}$  וזו פונקציית ההתפלגות המצטברת של מ"מ אקספוננציאלי. לכן  $W_n \xrightarrow{D} \exp(1)$

**הגדרה:** יהי  $X$  מ"מ. פונקציה יוצרת מומנטים שלו מוגדרת להיות  $M(s) = E[e^{sX}]$

**טענה:** יהי  $X$  מ"מ,  $M(s)$  פונקציה יוצרת מומנטים שלו. אזי  $E[X^k] = M^{(k)}(0)$

**משפט:** המומנטים (מכל סדר) של מ"מ  $X$  קובעים את ביחידות.

**משפט (משפט הגבול המרכזי - Central Limit Theorem):** יהיו  $X_1, \dots, X_n$  מ"מ בלתי-תלויים שווי התפלגות ונגדיר  $S_n = X_1 + \dots + X_n, M_n = \frac{S_n}{n}$

נסמן  $\mu = E[X_i], \sigma^2 = Var(X_i)$ . אזי  $M_n = \frac{S_n - \mu n}{\sigma \sqrt{n}}$  נגדיר מ"מ חדש  $Z_n = \frac{S_n - \mu n}{\sigma \sqrt{n}}$  אזי מתקיים  $\lim_{n \rightarrow \infty} P(Z_n \leq z) = \Phi(z)$  כלומר  $Z_n$  מתכנסת בהתפלגות למ"מ נורמלי סטנדרטי,  $N(0,1)$ .

• אם  $X, Y$  מ"מ ב"ת אז  $M_{X+Y}(s) = M_X(s)M_Y(s)$   
 • אם  $Y = aX + b$  אז  $M_Y(s) = E[e^{s(aX+b)}] = e^{sb} E[e^{asX}] = e^{sb} M_X(sa)$

• זבובים נכנסים לחדר, ובחדר מלכות. הזבוב ה- $i$  שנכנס יתפס במלכות בהסתברות  $p$ . כלומר  $X_i \sim Ber(p)$  ב"ת ו"ש.  $N \sim Pois(\lambda)$  ו"ש הזבובים שנכנסו לחדר, ונתון  $N \sim Pois(\lambda)$  ו"ש הזבובים שנתפסו:

ניזכר ש- $M_{X_i}(s) = (1 - p + pe^s)$  ו- $M_N(s) = e^{\lambda(e^s - 1)}$

$$M_Y(s) = E[e^{sY}] = E\left[e^{s \sum_{i=1}^N X_i}\right] = E\left[E\left[e^{s \sum_{i=1}^N X_i} \mid N\right]\right]$$

נסתכל על  $N = n$  ספציפי:

$$E\left[e^{s \sum_{i=1}^N X_i} \mid N = n\right] = E\left[e^{s \sum_{i=1}^n X_i}\right] = \prod_{i=1}^n (1 - p + pe^s) = (1 - p + pe^s)^n$$

ונחזור לתוחלת:

$$E[(1 - p + pe^s)^N] = \sum_{n=0}^{\infty} P(N = n)(1 - p + pe^s)^n = \sum_{n=0}^{\infty} e^{-\lambda} \frac{\lambda^n}{n!} (1 - p + pe^s)^n = e^{-\lambda} \sum_{n=0}^{\infty} \frac{(\lambda(1 - p + pe^s))^n}{n!} = e^{-\lambda} e^{\lambda(1 - p + pe^s)} = e^{\lambda p(e^s - 1)}$$

קיבלנו את ה-MGF של מ"מ פואסון:  $Y \sim Pois(\lambda p)$

**באמצעות המשפט ניתן לבצע קירוב נורמלי - הממוצע של קבוצת מ"מ ב"ת ש"ה בעלי תוחלת  $\mu$  ושונות  $\sigma^2$  ניתן לקירוב ע"י**

$$N\left(\mu, \frac{\sigma^2}{n}\right) \text{ והסכום ניתן לקירוב ע"י } N(\mu, \frac{\sigma^2}{n})$$

• ההסתברות שמערכת תקרוס ביום מסוים היא 5%. בשנה יש 300 ימי עבודה - מהי ההסתברות שהמערכת תקרוס בלא יותר מ-5 ימים בשנה?

• המ"מ של הקריסה בכל יום ב- $X_i \sim Ber(0.05)$  ומסתכלים על  $Y = \sum_{i=1}^{300} X_i$  ורוצים לדעת מה ההסתברות שערכו יהיה קטן או שווה ל-5. נבצע קירוב נורמלי, השונות והתוחלת ידועים:

$$P(Y \leq 5) = P\left(\frac{Y - 15}{\sqrt{14.25}} \leq \frac{5 - 15}{\sqrt{14.25}}\right) \cong \Phi(-2.65) \cong 0.004$$

נסתכל על  $1 - \alpha = P\left(-z_{1-\frac{\alpha}{2}} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq z_{1-\frac{\alpha}{2}}\right)$  והסתברות שווה ל- $1 - \alpha$  כיוון ש-

$$1 - 2P\left(Z \geq z_{1-\frac{\alpha}{2}}\right) = 1 - 2\left(1 - P\left(Z \leq z_{1-\frac{\alpha}{2}}\right)\right) = 1 - 2 + 2\left(1 - \frac{\alpha}{2}\right)$$

לאחר חילוף  $\mu$ , רווח הסמך:  $\mu \in \left[\bar{X} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right]$

**הגדרה:** בבדיקת השערות עלינו לבנות מבחן מהצורה  $T(X) \geq c$  כאשר  $X$  מדגם מקרי  $(X_1, \dots, X_n)$  ("ת"ש") עבור שתי השערות -  $H_0$  השערת האפס,  $H_1$  השערת האלטרנטיבה, כאשר המבחן דוחה את השערת האפס.

**הגדרה:** נסמן ב- $R$  את קבוצת המדגמים שעבורם המבחן דוחה את  $H_0$ . אז רמת המובהקות (significance) תסומן  $\alpha := P_{H_0}((X_1, \dots, X_n) \in R)$  ועוצמת המבחן (power) תסומן  $1 - \beta := P_{H_1}((X_1, \dots, X_n) \in R)$ .

בהינתן מבחן מסוים ו- $n$ , קביעת  $\alpha$  קובעת גם את  $\beta$ . אם רוצים להקטין את שניהם, אין ברירה אלא להגדיל את  $n$ .

**הגדרה:** יהי  $x_1, \dots, x_n$  מדגם ספציפי ונסמן ב- $T(x_1, \dots, x_n)$  את ערך הסטטיסטי עבור המדגם (המבחן). ה-p-value של המדגם הוא ההסתברות  $P_{H_0}(T(X) \geq T(x_1, \dots, x_n))$ . (כאן  $X$  הוא מ"מ של כל המדגם, כלומר  $(X_1, \dots, X_n)$ ).

ככל שה-p-value גדול יותר, כך המדגם יותר סביר בהינתן  $H_0$ . בעצם, ה-p-value של המדגם  $x_1, \dots, x_n$  הוא הערך של  $\alpha$  אילו היינו בוחרים לקבוע את הסף של המבחן ב- $T(x_1, \dots, x_n)$ .

**טענה:** ה-p-value מתפלג אחיד בין 0 ל-1.

**הגדרה:** מבחן יחס הנראות לבדיקת השערות הוא מבחן מהצורה  $L(X) = \frac{P_{H_1}(X_1, \dots, X_n)}{P_{H_0}(X_1, \dots, X_n)} \geq c$

יהיו  $X_i \sim \text{Pois}(\theta)$  והשערות:  $H_0: \theta = \theta_0, H_1: \theta = \theta_1$  עבור  $\theta_0 < \theta_1$ . נבנה כלל דחיה על פי מבחן יחס הנראות:

$$L(X_1, \dots, X_n) = \frac{P_{H_1}(X_1, \dots, X_n)}{P_{H_0}(X_1, \dots, X_n)} = \frac{\prod_{i=1}^n e^{-\theta_1} \frac{\theta_1^{X_i}}{X_i!}}{\prod_{i=1}^n e^{-\theta_0} \frac{\theta_0^{X_i}}{X_i!}} = \prod_{i=1}^n e^{-(\theta_1 - \theta_0)} \left(\frac{\theta_1}{\theta_0}\right)^{X_i}$$

$$= e^{-(\theta_1 - \theta_0)n} \left(\frac{\theta_1}{\theta_0}\right)^{\sum_{i=1}^n X_i} \geq c$$

זו פונקציה מונוטונית עולה של  $\sum_{i=1}^n X_i$  (כי  $\theta_0 < \theta_1$  ולכן הבסיס גדול מ-1), והמבחן הזה שקול למבחן  $\sum_{i=1}^n X_i \geq c'$ .

**משפט (נימון-פירסון):** יהי  $L(X) \geq c$  מבחן יחס הנראות עבור שתי השערות,  $R$  - תחום דחיית  $H_0$ ,  $\alpha, \beta$  כרגיל. יהי  $X \in S$  מבחן כלשהו,  $S$  - תחום דחיית  $H_0$ ,  $\alpha', \beta'$  כרגיל. אזי  $\alpha' \leq \alpha \Rightarrow \beta' \leq \beta$ .

כלומר, לא ניתן לשפר את  $\alpha$  מבלי לפגוע ב- $1 - \beta$ .

**הגדרה:** מבחן יחס נראות מוכלל הוא מבחן בדיקת השערות מהצורה  $H_0: \theta \in \Theta_0, H_1: \theta \in \Theta_1$  שסף הדחייה שלו הוא  $L(X) = \frac{\max_{\theta \in \Theta_1} P(X_1, \dots, X_n; \theta)}{\max_{\theta \in \Theta_0} P(X_1, \dots, X_n; \theta)} \geq c$

לעתים אפשר יהיה להשתמש באומד נראות מירבית שכבר ידוע לנו כדי למצוא את ערך המקסימום במונה/במכנה.

**הגדרה:** אומד (או סטטיסטי) הוא פונקציה  $\hat{\theta}: (X_1, \dots, X_n) \rightarrow \theta$  המחזירה עבור מדגם אקראי אומדן - את הערך של הפרמטר שמתאים למדגם שהתקבל:  $\hat{\theta}(x_1, \dots, x_n) = \theta$ .

**הגדרה:** הטייה של אומד  $\hat{\theta}$  מסומנת ומוגדרת  $Bias(\hat{\theta}) = E[\hat{\theta}(X)] - \theta^*$ , כאשר  $\theta^*$  הערך "אמיתי" של הפרמטר. אומד שהטייה שלו היא 0 נקרא אומד חסר-הטייה.

**הגדרה:** אומד ייקרא קונסיסטנטי (עקבי) אם  $\hat{\theta}(X) \xrightarrow{p} \theta^*$ .

תכונות שנרצה שיהיו לאומד:

(1) אם נחזור על התהליך, נקבל תוצאות (אומדנים) דומים -

כלומר,  $Var(\hat{\theta}(X))$  נמוך

(2) קונסיסטנטיות

(3) הטייה קטנה (או לא מוטה)

**הגדרה:** פונקציית הפסד (או טעות) של אומד  $\hat{\theta}$  מוגדרת  $L(\hat{\theta}(X), \theta^*)$  וההפסד (או סיכון) תחת פונקציית הפסד כזאת מוגדר  $E[L(\hat{\theta}(X), \theta^*)]$ .

**הגדרה:** Mean Squared Error היא פונקציית הפסד המוגדרת  $L(\hat{\theta}(X), \theta^*) = (\hat{\theta}(X) - \theta^*)^2$  וההפסד לפי פונקציה זו מסומן  $R := E[(\hat{\theta}(X) - \theta^*)^2]$

$$R = Var(\hat{\theta}(X) - \theta^*) + E[\hat{\theta}(X) - \theta^*]^2 = Var(\hat{\theta}(X)) + Bias(\hat{\theta})^2$$

**הגדרה:** יהיו  $X_i \sim f_X(x; \theta)$  או  $(P_X(x; \theta))$ . אומד הנראות המירבית (Maximum Likelihood Estimator) מוגדר להיות  $\hat{\theta}(X) = \text{argmax}_{\theta} f_X(x_1, \dots, x_n; \theta)$

**הגדרה:** אומד  $\hat{\theta}(X)$  הוא אסימפטוטי נורמלי אם מתקיים

$$\sqrt{n}(\hat{\theta}(X) - \theta^*) \xrightarrow{D} N(0, \sigma_{\hat{\theta}}^2)$$

כאן  $\sigma_{\hat{\theta}}^2$  השונות של ה"טבע".

יהי  $\hat{\theta}(X) = \bar{X}$  ונניח  $E[X_i] = \theta^*$  ו- $Var(X_i) = \sigma_{\theta^*}^2$  כלומר אומדים את התוחלת של ה"טבע". כעת לפי משפט הגבול המרכזי,  $\frac{\bar{X} - \theta^*}{\sigma_{\theta^*}/\sqrt{n}} \xrightarrow{D} N(0, 1) \Rightarrow \sqrt{n}(\bar{X} - \theta^*) \xrightarrow{D} N(0, \sigma_{\theta^*}^2)$  ולכן זהו אומד אסימפטוטי נורמלי (לתוחלת).

**משפט:** MLE הוא קונסיסטנטי ואסימפטוטי נורמלי.

**הגדרה:** יהי  $X$  מדגם מקרי  $X_1, \dots, X_n$  הנדגמים באופן "ת"ש" מתוך הטבע,  $f_X(x; \theta)$ . רווח סמך (Confidence Interval) הוא זוג פונקציות  $U, V$  המספקות א"ש  $U(X) \leq \theta \leq V(X)$ .

(1) מוצאים פונקציה  $g(X; \theta)$  כך שההתפלגות של  $g$  אינה תלויה ב- $\theta$  (יש לבדוק זאת)

(2) נחפש  $a, b$  כך ש- $1 - \alpha = P(a \leq g(X_i; \theta) \leq b)$  אז

(3) מחלצים רווח סמך על  $\theta$

עבור  $X_i \sim N(\mu, \sigma^2)$  כאשר אומדים את  $\mu$  (ידועה):

נגדיר  $g(X; \theta) = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  שהוא מ"מ נורמלי סטנדרטי ואינו תלוי בפרמטר.