

פונקציות התפלגות מצטברות:

הגדרה:  $F_X(x) = P(X \leq x)$

רציפה:  $F_X(x) = \int_{-\infty}^x f_X(x) dx$

1)  $0 \leq F_X(x) \leq 1$

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

4)  $f_X(x) = \frac{d}{dx} F_X(x)$

2)  $F_X(x)$  לא יורדת.

5)  $f_X(x) = \frac{d}{dx} F_X(x)$  רציפה מימין.

6) לכל פונקציה  $F_X(x)$   $Uni(0,1)$

נורמלי  $f_Z(z) = \frac{1}{\sqrt{2\pi}} e^{-z^2/2}$

1)  $0 \leq F_X(x) \leq 1$

2)  $Cov(X,Y) = E((X-\mu_X)(Y-\mu_Y)) = E(XY) - E(X)E(Y)$

3)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

5)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

6)  $Var(aX+b) = a^2 \cdot Var(X)$

7)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

9)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

10)  $Var(aX+b) = a^2 \cdot Var(X)$

11)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

13)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

14)  $Var(aX+b) = a^2 \cdot Var(X)$

15)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

17)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

18)  $Var(aX+b) = a^2 \cdot Var(X)$

19)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

21)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

22)  $Var(aX+b) = a^2 \cdot Var(X)$

23)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

25)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

26)  $Var(aX+b) = a^2 \cdot Var(X)$

27)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

29)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

30)  $Var(aX+b) = a^2 \cdot Var(X)$

31)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

33)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

34)  $Var(aX+b) = a^2 \cdot Var(X)$

35)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

37)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

38)  $Var(aX+b) = a^2 \cdot Var(X)$

39)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

41)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

42)  $Var(aX+b) = a^2 \cdot Var(X)$

43)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

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

45)  $Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

46)  $Var(aX+b) = a^2 \cdot Var(X)$

47)  $Var(X+Y) = Var(X) + Var(Y) + 2Cov(X,Y)$

שינוי וסטיית תקן:

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

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

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

$Corr(X,Y) = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$

$Var(aX+b) = a^2 \cdot Var(X)$

התפלגות משותפת ושולית:

$P(X=x, Y=y) = P_{XY}(x,y)$

$P_X(x) = \sum_y P_{XY}(x,y)$

$P_Y(y) = \sum_x P_{XY}(x,y)$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

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

$E(aX+b) = aE(X) + b$

$E(g(X,Y)) = \sum_{x,y} g(x,y) \cdot P(X=x, Y=y)$

$E(g(X)) = \sum_x g(x) \cdot P(X=x)$

$P(X \leq x) = \sum_{x \in R_X} P(X=x)$

$\sum_x P(X=x) = 1$

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

$E(aX+b) = aE(X) + b$

$E(g(X,Y)) = \sum_{x,y} g(x,y) \cdot P(X=x, Y=y)$

$E(g(X)) = \sum_x g(x) \cdot P(X=x)$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

$\sum_x P(X=x) = 1$

$E(XY) = E(X)E(Y) + Cov(X,Y)$

$E(XY) = \sum_{x,y} xy P(X=x, Y=y)$

$E(X) = \sum_x x P(X=x)$

פונקציית הסתברות של מ"מ:  $0 \leq P(X=x) \leq 1$

ניסויים ב"ת והתפלגויות בדידות:

ניסוי ברנולי (p):  $Ber(p)$  ניסוי בעל שתי תוצאות

האפשרויות: 'הצלחה' / 'כישלון' -  $F: EX=p, Var(X)=pq$  bin / n

התפלגות בינומית (n,p):  $Bim(n,p)$  הצלחות בסדרה של n ניסויים שלכל אחד

הסתברות הצלחה  $p$ :  $P(k) = \binom{n}{k} p^k q^{n-k}$

סכום בינומיים: אם  $X \sim B(n,p)$  וגם  $Y \sim B(m,p)$  (אותו p בשניהם) אז  $X+Y \sim B(m+n,p)$

התפלגות גאומטרית (Geo(p)): הצלחות להצלחה ראשונה בסדרה של n ניסויים שלכל אחד

הסתברות להצלחה  $p$ :  $P(k) = (1-p)^{k-1} p$

הסתברות להצלחה בכל ניסוי היא  $p$ :  $P(k) = (1-p)^{k-1} p$

חוסר זיכרון: אם ידוע שלא הייתה הצלחה עד לניסוי

ה-n אז ההסתברות כי היא תתקרה בניסוי k+n היא

עדיין כמו בנסוחה. התפלגות בינומית שולית (NB(m,p)): ההסתברות לקבל את ההצלחה ה-mית מ-n ניסויים

בניסויים n. כאשר לכל ניסוי הסתברות הצלחה p.

כמו סכום של גיאומטרי  $P(k) = \binom{k-1}{m-1} p^m q^{k-m}$

התפלגות היפר-גיאומטרית (HG(N,D,n)): כבד

מציאים n כדורים שחורים M- כדורים לבנים.

מוציאים n כדורים באקראי ללא החזרה. ההסתברות

שבין הכדורים שהוצאו נמצאים k כדורים שחורים.

$P(k) = \frac{\binom{D}{k} \binom{N-D}{n-k}}{\binom{N}{n}}$   $n < N, D < N$

מרבנה סוגים: כאשר  $n_1 + \dots + n_k = n$  ובחורים n.

$P(n_j \text{ of type } 1 \leq j \leq k) = \frac{\binom{N_1}{n_1} \binom{N_2}{n_2} \dots \binom{N_k}{n_k}}{\binom{N}{n}}$

קירוב בינומי להיפר גיאומטרי: כאשר N גדול מאוד

ביחס ל-n, אז תוצאות החישוב עם ההחזרה

(הבינומית) קרובה לתוצאות החישוב בלי החזרה

(ההיפר גיאומטרית).  $p=D/N, n=N$

$X \sim HG(n, N, M) \Rightarrow X \sim Bim(n, \frac{M}{N+M})$

התפלגות פואסון בדידה (Pois(lambda)): מספר האירועים

ביחידת זמן נתונה, אם ידוע כי הם מתרחשים בקצב

ממוצע קבוע  $\lambda > 0$  ובאופן ב"ת בפרק הזמן מאז

האירוע האחרון.  $P(k) = \frac{e^{-\lambda} \lambda^k}{k!}$

מירוצ פואסון:  $X_1 | X_1 + X_2 = n \sim Bim(n, \frac{\lambda_1}{\lambda_1 + \lambda_2})$

קירוב פואסוני לבינומי: כאשר n גדול ו-p קטן אז

ניתן לקרב את הבינומי לפואסוני עם  $\lambda = np$ .

הערה! ניתן לעשות קירוב נורמלי לבינומי-מג'מ!

סכום פואסונים ב"ת:  $Y \sim Pois(\mu), X \sim Pois(\lambda) \Rightarrow X+Y \sim Pois(\mu+\lambda)$

פיצול פואסון: אם  $Z \sim Pois(\mu)$  וזו מתרחש אחד

משני מאורעות בהסתברויות  $p_a + p_b = 1$  אז נקבל

מ"מים ב"ת שמתפלגים  $Pois(p_a \cdot \mu), Pois(p$

רווח סמך:

רו"ס לתוחלת במדגם מהתפלגות נורמלית: כאשר  $\sigma$  ידוע: כאשר  $\sigma$  לא ידוע:

Q = (X-bar - mu) / (S / sqrt(n)) ~ t(n-1)
mu in X-bar +/- t(n-1, 1-alpha/2) \* S / sqrt(n)

תכונות:

- 1. זהו רווח סמך הקצר ביותר ברמת סמך נתונה.
2. ארוכו קבוע מראש רק כאשר השונות ידועה.
3. אורך הרווח עולה עם הגדלת רמת הסמך והשונות.
4. אורך הרווח קטן עם עליה בגודל המדגם.

גודל המדגם הדרוש כדי שביטחון של 1-alpha הסטייה בין ממוצע המדגם ל mu לא תעלה על d:

2 \* z(1-alpha/2) \* sigma / sqrt(n) <= d -> n >= (z(1-alpha/2) \* sigma / d)^2

רו"ס ל- theta במדגם מהתפלגות אחידה:

Q(X(n), theta) = X(n)/theta ~ N(X(n), X(n)/alpha^2)

רו"ס לפרופורציה במדגם מהתפלגות נורמלית:

X\_i ~ Ber(p), p-hat = X/n ~ N(p, p(1-p)/n)
Q = (p-hat - p) / sqrt(p(1-p)/n) ~ N(0,1) p in p-hat +/- z(1-alpha/2) \* sqrt(p(1-p)/n)

גודל המדגם כדי שביטחון של 1-alpha הפרופורציה במדגם ל p לא תעלה על d:

n >= (z(1-alpha/2) \* sqrt(p(1-p)) / d)^2, p(1-p) <= 0.25, n >= (z(1-alpha/2) / 4d)^2

רו"ס לשונות במדגם מהתפלגות נורמלית: כאשר mu ידוע:

Q = 1/sigma^2 \* sum(X\_i - mu)^2 ~ chi^2(n)
sigma^2 in [sum(X\_i - mu)^2 / chi^2(n, 1-alpha/2), sum(X\_i - mu)^2 / chi^2(n, alpha/2)]

כאשר mu לא ידוע:

Q = (n-1)S^2 / sigma^2 ~ chi^2(n-1)
sigma^2 in [sum(X\_i - X-bar)^2 / chi^2(n-1, 1-alpha/2), sum(X\_i - X-bar)^2 / chi^2(n-1, alpha/2)]

תכונות:

- 1. אינו רווח סמך אופטימלי עבור רמת סמך נתונה.
2. רווח סמך עבור סטיית תקן: שורש על שני הקצוות.

רו"ס ל- alpha במדגם מהתפלגות Gamma:

Y = -ln(X), Y ~ exp(alpha)
Q = 2 \* sum(Y\_i) ~ Gamma(n, 1/2) = chi^2(2n)
alpha in [sum(Y\_i) / chi^2(2n, alpha/2), sum(Y\_i) / chi^2(2n, 1-alpha/2)]

רו"ס להפרש תוחלות בשני מדגמים ב"ת:

Q = ((X-bar - Y-bar) - (mu\_X - mu\_Y)) / sqrt(sigma^2 \* (1/n + 1/m)) ~ N(0,1)
mu\_X - mu\_Y in (X-bar - Y-bar) +/- z(1-alpha/2) \* sqrt(sigma^2 \* (1/n + 1/m))

כאשר sigma לא ידוע והשונות זהות:

S\_p^2 = ((n-1)S\_x^2 + (m-1)S\_y^2) / (n+m-2)
Q = ((X-bar - Y-bar) - (mu\_X - mu\_Y)) / sqrt(S\_p^2 \* (1/n + 1/m)) ~ t(n+m-2)
mu\_X - mu\_Y in (X-bar - Y-bar) +/- t(n+m-2, 1-alpha/2) \* sqrt(S\_p^2 \* (1/n + 1/m))

כאשר sigma לא ידוע והשונות שונות:

mu\_X - mu\_Y in (X-bar - Y-bar) +/- t(df, 1-alpha/2) \* sqrt(S\_x^2/n + S\_y^2/m)
df = (S\_x^2/n + S\_y^2/m) / (S\_x^4/n^2 + S\_y^4/m^2)

רו"ס להפרש תוחלות בשני מדגמים מווגים: בניגוד מדגם של הפרשים

mu\_X - mu\_Y = mu\_D, D\_i ~ N(mu\_D, sigma\_D^2)
S\_D^2 = 1/(n-1) \* sum(D\_i - D-bar)^2, mu\_D in D-bar +/- t(n-1, 1-alpha/2) \* S\_D / sqrt(n)

רו"ס ליחס שונות בשני מדגמים ב"ת:

Q = (S\_x^2 / sigma\_x^2) / (S\_y^2 / sigma\_y^2) ~ F(1, n-1)
lambda = (sigma\_x^2 / sigma\_y^2) in [S\_x^2 / S\_y^2 \* F(1-alpha/2, n-1, 1-alpha/2), S\_x^2 / S\_y^2 \* F(1-alpha/2, n-1, 1-alpha/2)]

רו"ס להפרש פרופורציות בשני מדגמים ב"ת:

Q = ((p-hat\_X - p-hat\_Y) - (p\_X - p\_Y)) / sqrt(p-hat\_X(1-p-hat\_X)/n + p-hat\_Y(1-p-hat\_Y)/m) ~ N(0,1)
(p-hat\_X - p-hat\_Y) +/- z(1-alpha/2) \* sqrt(p-hat\_X(1-p-hat\_X)/n + p-hat\_Y(1-p-hat\_Y)/m)

התפלגויות דיגמה: התפלגות נורמלית:

X\_1, ..., X\_n ~ N(mu, sigma^2)
X\_0.95 = Z\_0.95 \* sigma + mu, Z\_0.15 = -Z\_0.85

התפלגות הממוצע:

X-bar ~ N(mu, sigma^2/n) -> (X-bar - mu) / (sigma / sqrt(n)) ~ N(0,1)

הסתברות שהסטייה המוחלטת לכל היותר d:

P(|X-bar - mu| <= d) = 2 \* Phi(d / (sigma / sqrt(n))) - 1

גודל המדגם כדי ש: P(|X-bar - mu| <= d) >= 1 - alpha

n >= (z(1-alpha/2) \* sigma / d)^2

חוק התקנון: חוק התפלגות חכי-בריבוע:

1. צפיפות לא סימטרית עם זנב ימני.
2. התפלגות חיובית.
3. עבור n > 50, קרוב לנורמלי.

chi^2(n) + chi^2(m) = chi^2(n+m)
W\_n = sum(Z\_i^2) ~ Gamma(n, 1/2)
W\_n = 1/sigma^2 \* sum(X\_i - mu)^2 ~ chi^2(n)

קשר ל-Gamma ולנורמלי:

W\_n ~ Gamma(n, 1/2)
W\_n / n -> 1, W\_n - n / sqrt(2n) -> N(0,1)

E(W\_n) = n, Var(W\_n) = 2n

התפלגות שונות המדגם:

sigma^2 = 1/n \* sum(X\_i - mu)^2
לא ידועה: sigma^2 = 1/n \* sum(X\_i - X-bar)^2

sum(X\_i - mu)^2 / sigma^2 ~ chi^2(n), sum(X\_i - X-bar)^2 / sigma^2 ~ chi^2(n-1)
E(chi^2(n-1)) = n-1, Var(chi^2(n-1)) = 2(n-1)

ההסתברות שאני"מ לשונות במדגם נורמלי יסטה ממנה בסטייה יחסית שונה עולה על epsilon:

sigma^2 = 1/n \* sum(X\_i - mu)^2 \* P(|sigma^2 - sigma^2| <= epsilon) = P(W\_n <= n(1+epsilon)) - P(W\_n <= n(1-epsilon))

התפלגות t:

T = Z / sqrt(W\_k/k) ~ t(k)
E(T) = 0, Var(T) = k / (k-2)

תכונות:

- 1. סימטרית סביב 0.
2. זנבות עבים משל הנורמלית.

כאשר השונות לא ידועה: (X-bar - mu) / (S / sqrt(n)) ~ t(n-1)

t(n, 0.1) = -t(n, 0.9)

התפלגות F:

F(k, m) = (W\_k/k) / (W\_m/m) ~ F(k, m)
E(F) = k / (m-2)
Var(F) = (2m^2(k+m-2)) / (k(m-2)^2(m-4))

תכונות:

- 1. התפלגות לא סימטרית עם ד"ח במונה ובמכנה.
2. F(k, m) = 1 / F(m, k)

בראש הטבלה: הסתברות p-במנים: P(X <= a) = p, a

סטטיסטיקה תיאורית ושיטות גרפיות: שגיאת דיגמה: שגיאה כתוצאה מכך שנאספו נתונים על מדגם שהינו חלק מכלל האוכלוסייה. גודלה תלוי בשיטת הדיגמה ובגודל המדגם. ממוצע קטום: ממוצע ללא המונח והגבוהו.

שברון p באוכלוסייה: P(X <= xi\_p) = p, xi\_p

הערך ש- p% מהאוכלוסייה מתחתיו. חישוב השברון המדגמי:

r = (n+1)p - [(n+1)p]
(1-r)X(k) + rX(k+1)

רבעון ראשון-Q1:

Q1 = 3/4 \* X((n+1)/4) + 1/4 \* X(((n+1)/4)+1)

ציון-M:

M = 1/2 \* X((n+1)/2) + 1/2 \* X(((n+1)/2)+1)

אי-זוגי:

M = X(((n+1)/2))

רבעון שלישי-Q3:

Q3 = 1/4 \* X(3(n+1)/4) + 3/4 \* X(((3(n+1)/4)+1))

שונות המדגם:

S^2 = 1/(n-1) \* sum(X\_i - X-bar)^2

BOX-PLOT: מומנטים הם עקיבים (וח"ח, וגם אמד שהוא מרי רציפה שלהם.

step = 3/2 \* (Q3 - Q1)
LF = Q1 - step, UF = Q3 + step

LF: התצפית המינימלית שגדולה מ-LF.
UF: התצפית המקסימלית שקטנה מ-UF.

אמידה נקודתית:

סטטיסטי: פונקציה של התצפיות במדגם.
פרמטר: נודל שהוא מפיין מסכם של האוכלוסייה.
אמד: סטטיסטי שאיתו אומדים את הפרמטר.
אומדל: הערך של האמד, המחושב מהמדגם.
שיטת המומנטים:

מומנט k-באוכלוסייה: mu\_k = E(X^k)
מומנט k-המדגמי: M\_k = 1/n \* sum(X\_i^k)

השיטה: מבטאים את הפרמטר ע"י המומנטים של האוכלוסייה ואז מציינים במקומם את המומנטים של המדגם

דיגמא: f(x|theta) = (theta+1)x^theta, 0 <= x <= 1

mu\_1 = E(X) = 1/(theta+2)
theta = 1/(1-mu\_1) - 2 -> theta-hat = 1/(1-M1) - 2

אמידת התוחלת (הפרמטר הוא -mu):

theta-hat = M1 = X-bar, E(theta-hat) = mu, Var(theta-hat) = 1/n \* Var(X1)

אמידת השונות (הפרמטר הוא sigma^2):

theta-hat = S^2 = 1/n \* sum(X\_i - X-bar)^2, E(theta-hat) = sigma^2

שיטת הנראות המירבית:

בחירת הערך q עבורו ההסתברות של תוצאות המדגם היא הגדולה ביותר.
פונקציית נראות: מרי צפיפות משותפת-

L(theta | x1...xn) = f\_theta(x1...xn) = prod f\_theta(x\_i)
מוצאים אמד שימקסם את L(theta) ע"י גזירה והשוואה ל-0.

תכונות:

- 1. אני"מ אינו בהכרח יחיד.
2. לפעמים קל יותר למקסם את l(theta) = ln L(theta)
3. אם theta אני"מ ל- theta אז לכל פו tau, tau(theta) = tau(theta-hat)

דיגמא:

L(theta) = prod (theta+1)x\_i^theta = (theta+1)^n \* prod x\_i^theta
l(theta) = ln(L(theta)) = n ln(theta+1) + theta \* sum ln(x\_i)

delta L(theta) / delta theta = n / (theta+1) + sum ln(x\_i) = 0 -> theta-hat = n / (-sum ln(x\_i) - 1)

כאשר x מוגבל ע"י הפרמטר, מכניסים אינדקטור

דיגמא:

L(theta) = prod lambda \* e^{-lambda \* x\_i} \* I{x\_i >= 0}
= lambda^n \* e^{-lambda \* sum(x\_i)} \* I{X(1) >= 0}
= e^{n \* ln lambda - lambda \* sum(x\_i)} \* I{X(1) >= 0} -> theta-hat = X(1)

חוסר הטייה: ממוצע האומדנים יהיה שווה בקירוב לערך הפרמטר אותו רוצים לאמוד. theta-hat

E(theta-hat) = theta

השגיאה הריבועית הממוצעת-תוחלת הסטייה:

MSE\_theta-hat(theta) = E(theta-hat - theta)^2 = Var(theta-hat) + (E(theta-hat) - theta)^2

התפלגות אחידה: האני"מ עדיף ל n >= 3 אבל הוא אמד מוטא. אח"ה: theta\* = (n+1)/n \* X(n)

MSE\_theta-hat(theta) approx MSE\_theta\*(theta)
לפי ה-MSE: MSE\_theta-hat(theta) approx MSE\_theta\*(theta)

עקיבות: אומד שה-MSE שלו שואף ל-0.

MSE\_theta-hat(theta) approx MSE\_theta\*(theta)
אם epsilon > 0 לכל epsilon האמד

lim\_{n->inf} P(theta-hat - theta < epsilon) = 1

הערה: בד"כ כשה-MSE לא שואף ל-0, לא עקיב.
משפט: אם theta-hat עקיב ל- theta אז לפונקציה רציפה tau(theta-hat) עקיב ל- tau(theta) (ליניאריות שומרת אח"ה).

סטטיסטי מספיק: פונקציה שבה כל המידע במדגם ביחס לפרמטר.

הגדרה: S = S(X1...Xn) סטטיסטי מספיק אם ה"ח הצפיפות f(X1...Xn | S=s) אינו תלוי ב theta.

forall s, theta, S = S(X1...Xn) = s

תכונות:

- 1. אם theta אני"מ ל theta אז theta-hat הוא פרי של S.
2. S"מ אינו יחיד, אם S = g(S\*) וגם S\* = g(S\*)

משפט הפירוק: סטטיסטי S מספיק ביחס ל theta

f(x1...xn | theta) = h(x1...xn) \* g(S(x1...xn) | theta)

כלומר: מפרקים את f ל h - שתלוי רק בתצפיות ו- g שתלוי ב- S, כאשר S היא המידע מהתצפיות בתוך g.

משפט: אני"מ תלוי במדגם מקרי דרך S"מ.

(1/sigma)^n \* e^{-sum(x\_i)/sigma} \* e^{-sum(x\_i)/sigma} \* I{X(1) >= mu} -> S = X(1)

משפט Rao-Blackwell: theta-hat אחד ו- S אחד

- 1. E(theta-hat\*) = E(theta-hat)
2. E(theta-hat\*) <= E(theta-hat)
3. MSE\_theta-hat\*(theta) <= MSE\_theta-hat(theta)
מבוסס על ה"מ.

דיגמא: exp(lambda), Ber(p), אומד: X1. שיפורי:

E(X1 | sum(x\_i) = s) = P(X1=1 | sum(x\_i)=s) = s/n = X-bar

E(X1 | S) = s/n \* (n-1/n)^(s-1) = s/n \* (1-1/n)^(s-1) ~ Bin(s, 1/n) ~ Pois(lambda)