

פונקציות התפלגות מצטברות:

הגדרה: $F_X(x) = P(X \leq x)$

בדיד: $F_X(x) = \sum_{t \leq x} P(X=t)$ **רציני:** $F_X(x) = \int_{-\infty}^x f_X(x) dx$

(1) $0 \leq F_X(x) \leq 1$ (2) $F_X(x)$ לא יורדת.

(3) $\lim_{x \rightarrow -\infty} F_X(x) = 0$ $\lim_{x \rightarrow \infty} F_X(x) = 1$

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

(5) $f_X(x) = \frac{d}{dx} F_X(x)$ **לכל פונקציה.**

אם $E(X) < \infty$ אז $\lim_{x \rightarrow \infty} x \cdot (1 - F_X(x)) = 0$

התפלגות נורמלית: שימוש בטבלה עבור מ"מ

נורמלי $Z \sim N(0,1)$ $f_Z(z) = \frac{1}{\sqrt{2\pi}} e^{-z^2/2}$

$F_X \rightarrow P(Z \leq a) = \Phi(a)$ $P(a \leq Z \leq b) = \Phi(b) - \Phi(a)$

סכום נורמלים: $Y \sim N(\mu_2, \sigma_2^2)$ $X \sim N(\mu_1, \sigma_1^2)$ $X+Y \sim N(\mu_1+\mu_2, \sigma_1^2+\sigma_2^2)$

ב"ת אז $X+Y \sim N(\mu_1+\mu_2, \sigma_1^2+\sigma_2^2)$

מנת נורמלים: מתפלגות קושי. נורמלי ב-2: נאמא

משפט הגבול המרכזי: X_1, X_2, \dots, X_n ב"ת, ש"ה,

$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ $Var(\bar{X}_n) = \sigma^2/n$ $E(\bar{X}_n) = \mu$

אז: $\bar{X}_n \sim N(\mu, \sigma^2/n)$ כלומר $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \rightarrow N(0,1)$

כלומר $P\left(\frac{1}{\sigma/\sqrt{n}} \sum_{i=1}^n (X_i - \mu) \leq a\right) = \Phi(a)$

$\frac{S_n - n\mu}{\sqrt{n}\sigma} \rightarrow N(0,1)$ $S_n = \sum_{i=1}^n X_i$

התפלגות אחידה (וניפורמית): $U[0,1] \rightarrow f_U(x)=1$

$F_X \rightarrow P(c \leq X \leq d) = \frac{d-c}{b-a}$ $E(X) = \frac{a+b}{2}$

$Var(X) = \frac{(b-a)^2}{12}$ $f_X(x) = \frac{1}{b-a}$ $a \leq x \leq b$ otherwise

סטטיסטי הסדר: אם $X_1, X_2, \dots, X_n \sim U[0,1]$ **ב"ת:**

$f_{X_{(k)}}(x) = n \binom{n-1}{k-1} x^{k-1} (1-x)^{n-k}$

$E(X_{(k)}) = \frac{k}{n+1}$ $E(X_{(n)}) = \frac{n}{n+1}$

סטנדרטיזציה: $X \sim U[a,b] \rightarrow \frac{X-a}{b-a} \sim U[0,1]$

מעבר לאקספוננט: $U[0,1] \rightarrow \left(\frac{\ln(1-U)}{\lambda}\right) \exp(\lambda)$

התפלגות אקספוננציאלית: זמן בין מאורעות פואסון.

$P(X > a) = e^{-\lambda a}$ $E(X) = \frac{1}{\lambda}$ $Var(X) = \frac{1}{\lambda^2}$

$P(a \leq X \leq b) = e^{-\lambda a} - e^{-\lambda b}$ $f_X(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0 & otherwise \end{cases}$

מינימום של אקספוננט הוא אקספוננט:

$X \sim Exp(\lambda), Y \sim Exp(\mu) \Rightarrow \min(X, Y) \sim Exp(\lambda + \mu)$

תחרות בין אקספוננציאלים: ב"ת

$X \sim Exp(\lambda), Y \sim Exp(\mu) \Rightarrow P(X < Y) = \frac{\lambda}{\lambda + \mu}$

סכום עם גיאומטרי: $X_i \sim \exp(\lambda)$ $N \sim Geo(p)$

אז: $S_N = \sum_{i=1}^N X_i \sim \exp(\lambda p)$

תכונת חוסר זיכרון: אם נתון כי רגע t לא היה מופיע, אז הזמן עד למופע הבא מתחיל מהתחלה

$E(X-Y|X>Y) = EX$ $P(T > t+s | T > t) = P(T > s)$

משפט: נתון מ"מ T, נגדיר G(t) = P(T > t)

$G(t) = P(T > t)$ $G(t+s) = G(t) \cdot G(s)$ $T \sim Exp(\lambda)$ כך ש $G(t) = e^{-\lambda t}$

התפלגות Gamma: X_1, X_2, \dots, X_n מ"מ ב"ת,

$Y \sim Gamma(n, \lambda)$ $Y = \sum_{i=1}^n X_i$ נגדיר $X_i \sim Exp(\lambda)$

$f_X(x) = \begin{cases} \lambda^n x^{n-1} e^{-\lambda x} / \Gamma(n) & x \geq 0 \\ 0 & otherwise \end{cases}$

$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$ $\Gamma(n) = (n-1)! \Gamma(n-1)$ $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

חיבור Gamma: אם $X \sim Gamma(r, \lambda)$ $Y \sim Gamma(s, \lambda)$ אז $X+Y \sim Gamma(r+s, \lambda)$

חילוק Gamma: עבור X, Y כנ"ל יתקיים

$\frac{X}{X+Y} \sim Beta(r, s)$ $\frac{X}{X+Y} \sim Beta(r, s)$ $\frac{X}{X+Y} \sim Beta(r, s)$

$\Gamma(n) = (n-1)!$ $\Gamma(n, \lambda) = \int_{\lambda}^{\infty} t^{n-1} e^{-t} dt$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

כאשר n שלם: $\Gamma(n) = (n-1)!$

שינוי וסטיית תקן:

$Var(X) = E(X^2) - (E(X))^2 = E((X - E(X))^2)$

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

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

אם X, Y ב"ת: $Var(X+Y) = Var(X) + Var(Y)$

$Var(c) = 0$ קבוע אמ"מ $c \cdot Var(X|Y) = Var(X)$

$SD(aX+b) = |a| \cdot SD(X)$ $SD(X) = \sqrt{Var(X)}$

שינוי מותנית: $Var(Y|X) = E((Y-E(Y|X))^2|X)$

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

קו-וואריאנס: $Cov(X, X) = Var(X)$

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

$Cov(X, Y) = \frac{1}{2}(Var(X+Y) - Var(X) - Var(Y))$

(1) אם X, Y ב"ת אז $Cov(X, Y) = 0$

(2) אם $Cov(X, Y) = 0$ אז X, Y בלתי מתואמים.

(3) $Cov(X, Y) = Cov(Y, X)$ סימטריות.

(4) $Cov(aX+b, cY+d) = acCov(X, Y)$

(5) $Cov(X, X+Z) = Cov(Y, X) + Cov(X, Z)$

(6) לכל קבוע a : $Cov(X, a) = 0$

תקנון: $X^* = \frac{X-\mu_X}{\sigma_X}$ כאשר: $Corr(X, Y) = E(X^* Y^*)$

אינטגרלים: $\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

$\int_0^{\infty} e^{-x^2} dx = \frac{\sqrt{\pi}}{2}$ $\int_0^{\infty} \lambda e^{-\lambda x} dx = 1$

התפלגות משותפת ושולית:

התפלגות משותפת: חיתוך המאורעות

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

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

אי-תלות מ"מ בדידים: מ"מ הם ב"ת אם:

$\forall x, y: P_{XY}(x, y) = P_X(x) \cdot P_Y(y)$

אם ההסתברות משותפת היא מכפלת שתי פונקציות, האחת של x והשנייה של y,

אז ניתן להסיק שקיימת אי-תלות בין המשתנים.

הערה: פונקציות ותת-קבוצות זרות של מ"מ בלתי תלויים הן בלתי תלויות.

תוחלת: $E(X) = \sum_{x \in R_X} xP(X=x)$

$\sum_x |x| \cdot P(X=x) < \infty$

$E(X+Y) = EX + EY$ $E(aX+b) = aEX + b$

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

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

כלל הכפלה: אם X, Y ב"ת אז $E(XY) = E(X)E(Y)$

זוג מ"מ שמקיים את הנוסחה: **בלתי מתואמים.**

לכל שני מ"מ: $E(XY) = \sum_{x, y} xyP(X=x, Y=y)$

חוק המספרים הגדולים: עבור X_i ב"ת-1

$EX_i = \mu$ אז: $\frac{1}{n} \sum_{i=1}^n X_i \rightarrow \mu$ **החלט: לכל**

החוק: $P(|\bar{X}_n - \mu| \geq \epsilon) \rightarrow 0$ $\epsilon > 0$

$P\left(\lim_{n \rightarrow \infty} |\bar{X}_n - \mu| = 0\right) = 1$

נוסחת הזנב: $E(X) = \sum_{k=1}^{\infty} P(X \geq k)$ ($X \in \mathbb{N}$)

תוחלת מותנית:

$E(X|Y) = \sum_x x \cdot P(X=x|Y=y)$

$E(Y) = \sum_x E(Y|X=x) \cdot P(X=x)$

אם X, Y ב"ת $E(X|Y) = E(X)$

במקרה הרציני: $E(X|Y) = \int_{-\infty}^{\infty} x f_{X|Y}(x$

בדיקת השערות:

בעיות עיש לחליט בהן על אחת מבין 2 השערות. **השערת האפס:** ההשערה השמרנית, האמונה הרווחת. **האלטרנטיבה:** ההשערה החדשנית, המהפכנית. - החלטה שהשערה נכונה ע"י הוכחה שההשערה ההפוכה לא נכונה. - מקבלים תוצאה קיצונית תחת השערת האפס משתי השיות האבות: 1. מדגם לא מייצג 2. השערת האפס לא נכונה. **כלי החלטה:** חלוקת תוצאות האפשריים של תוצאות המדגם לשיני תחומים: **R** - אזור דחיית השערת האפס. **R^c** - אזור אי-דחיית השערת האפס.

H0	אי-דחיית H0
H1	דחיית H0
טעות מסוג I	טעות מסוג II
V	V


טעות מסוג I: דחיית השערת האפס כאשר היא נכונה. $\alpha = P(\text{type I error}) = P(\text{rejecting } H_0 | H_0 \text{ is true})$
טעות מסוג II: קבלת השערת האפס כאשר אינה נכונה. $\beta = P(\text{type II error}) = P(\text{not rejecting } H_0 | H_1 \text{ is true})$

הקטנת α תביא לעליה ב- β ולהפך. **השערה פשוטה:** השערה הקובעת באופן יחיד את התפלגות האוכלוסייה שממנה נלקח המדגם. **השערה מורכבת:** תוצאתה לא מאפשרת לקבוע את התפלגות האוכלוסייה. **פונקציית מבחן:** לכל כלל הכרעה ישנה פונקציית שקובעת את ההסתברות שבה נדחה את השערת האפס עבור התוצאה x . $\alpha = E_{H_0}(\phi_D(X))$, $\beta = E_{H_1}(1 - \phi(X))$.

רמת מובהקות: ההסתברות המרבית המותרת לטעות סוג I. רמת המובהקות שנקבעת תלויה במידת הנזק שייגרם כתוצאה מטעות מסוג I, אם הנזק גדול- נקבעת רמת מובהקות נמוכה. **הערה:** קובעים α מראש ומחפשים עבורו β קטן. **עוצמת של מבחן:** ההסתברות לדחיית השערת האפס כאשר האלטרנטיבה נכונה. $\pi = 1 - \beta = P_{H_1}(\text{reject } H_0)$

מבחן טוב: α קטן ו- β גדול. **דוגמא:** $X \sim \text{Bin}(3, p)$, $p \in \{1/4, 1/2\}$, $H_0: p=1/2$, $H_1: p=1/4$
כ"מ"מ 1/8, מהו מבחן בעל עוצמה מרבית? **X**-מספר הפעמים שהוא נופל על "עץ". $P_{H_0}(x=3)=1/8$, $P_{H_0}(x=0)=1/8$
 $\pi = P_{H_1}(x=3)=1/64$, $\pi = P_{H_1}(x=0)=24/64$

המבחן עם אזור דחייה-0 עדיף על זה עם אזור דחייה-3. **הקמה של ניימן-פירסן (מבחן יחס הנראות):** מבחן בעל עוצמה מרבית לבדיקת השערות הפשוטות: $H_0: X \sim f_0$; $H_1: X \sim f_1$



$\lambda(x) = \frac{f_1(x)}{f_0(x)}$, $\phi(x) = \begin{cases} 1 & \lambda(x) > k_\alpha \\ \tau & \lambda(x) = k_\alpha \\ 0 & \lambda(x) < k_\alpha \end{cases}$
 λ גבוה: f_1 יותר מתאים. λ נמוך: f_0 יותר מתאים. **מ"מ"מ בדיק:** $k_\alpha = k_\alpha$ נדחה את השערת האפס בסיכוי τ_α . **מ"מ רציף:** ישנם רק ערכים 0 ו-1. **דוגמא:** מדגם בגודל 10 מ- λ . $H_0: \lambda=1$, $H_1: \lambda=2$. $\exp(\lambda) = 2$

המבחן שקול ל: דחה H_0 אם: $\sum_{i=1}^n X_i < k_\alpha$ **מציאת C:** $\alpha = P_{H_0}(\text{reject } H_0) = P(\sum_{i=1}^n X_i < C) = P(2\lambda_0 \sum_{i=1}^n X_i < 2\lambda_0 C)$
 $P(\chi^2_{2n} < 2 \cdot 1 \cdot C) = P(\chi^2_{20} < 2C) = 0.05 \Rightarrow 2C = \chi^2_{20, 0.05}$
1: אם פונקציית יורדת של הסטטיסטי-X: דחייה- $X < C$.
2: אם פונקציית עולה של הסטטיסטי-X: דחייה- $X > C$.
הערה חשובה: השערת האפס היא היחידה שקובעת את אזור הדחייה ולכן הוא יישאר זהה גם לאלטרנטיבה אחרת. **מ"מ"מ מהתפלגות נורמאלית ושונות ידועה:**

מדגם מ- $N(\mu, \sigma^2)$, $H_0: \mu = \mu_0$, $H_1: \mu = \mu_1$. $N(\mu, \sigma^2)$
 $\lambda(x) = \exp\left\{-\frac{n\bar{x}(\mu_1 - \mu_0)}{\sigma^2} + \frac{n(\mu_0^2 - \mu_1^2)}{2\sigma^2}\right\} > k_\alpha$
אם $\mu_0 < \mu_1$ דחייה- $\bar{X} > \frac{\sigma}{\sqrt{n}} z_{1-\alpha} + \mu_0$
אם $\mu_1 < \mu_0$ דחייה- $\bar{X} < -\frac{\sigma}{\sqrt{n}} z_{1-\alpha} + \mu_0$

עוצמת המבחן גדלה כאשר:
1. ככל שההפרש $\mu_1 - \mu_0$ גדול יותר.
2. ככל ש- n גדול יותר.
3. ככל שטיית התקן של האוכלוסייה- σ קטנה.
4. גודל המדגם המינימאלי הדרוש לעוצמה ור"מ נתונות:
 $m = \frac{(\mu_1 - \mu_0)^2 \sigma^2}{(\mu_1 - \mu_0)^2}$

מבחן בעל עוצמה מרבית במידה שווה:

האלטרנטיבה מורכבת ממכה חלקים. אז כל ערך שרירותי f_1 מהאלטרנטיבה, המבחן של ניימן-פירסן (שנקבע רק לפי השערת האפס) הוא הטוב ביותר: **בעל עוצמה מרבית לכל השערה פשוטה מתוך האלטרנטיבה.** **Pvalue:** בהינתן תוצאת מדגם מסוימות, 1. ההסתברות לקבל תוצאה קיצונית **לפחות** כמו התוצאה שהתקבלה בניסוי, בהנחה שהשערת האפס נכונה. 2. רמת המובהקות הקטנה ביותר שעבורה נדחה את השערת האפס.

אם $\alpha \geq Pvalue$ נדחה בר"מ α
אם $\alpha < Pvalue$ לא נדחה בר"מ α
הערה: לכל שנגדיל את- n , $Pvalue$ קטן כי הערך שהתקבל במדגם יהיה יותר "זקן" ואז הוא ייחשב יותר קיצוני תחת השערת האפס. **דוגמא:** התפלגות פואסון- השערה מורכבת: $n=10$, $X_i \sim \text{Pois}(\lambda)$, $H_0: \lambda=4$, $H_1: \lambda < 4$

קירוב לנורמאלי: $\sum X_i \sim \text{Pois}(10\lambda)$
 $E(\sum X_i) = \text{Var}(\sum X_i) = 10\lambda$
 $\frac{\sum X_i - 10\lambda}{\sqrt{10\lambda}} \sim N(0,1)$
המבחן: דחייה- $Z = \frac{\sum X_i - 10\lambda_0}{\sqrt{10\lambda_0}} < -z_{1-\alpha}$

בדיקת השערה דו-צדדית:

$H_0: \mu = \mu_0$, $H_1: \mu \neq \mu_0$, $N(\mu, \sigma^2)$
מבחנים שונים עבורם נדחה את H_0 :
1. $\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} > z_{1-\alpha/2}$ or $\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} < -z_{1-\alpha/2}$
2. r ס: $\mu_0 \notin \bar{X} \pm z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}$ **לפי דף השערות**
3. $Pvalue = P_{H_0}(Z > X) + P_{H_0}(Z < -X)$
הערה: אזור דחייה בהשערה דו-צדדית יהיה מורכב משני חלקים **זהים בגודלם** בכל התפלגות, סימטרית או לא. (ולכן כאן: $Pvalue = 2 P_{H_0}(Z < -X)$)

חישוב עוצמת המבחן: $\pi = 1 - \beta$
 $\beta = P(Z \leq -z_{1-\alpha/2} + \frac{\mu_0 - \mu_1}{\sigma/\sqrt{n}})$
 $-P(Z \leq -z_{1-\alpha/2} + \frac{\mu_0 - \mu_1}{\sigma/\sqrt{n}})$
בדיקת שתי השערות מורכבות:
 $H_0: \theta \in W$, $H_1: \theta \in W^c$
ר"מ: $\alpha = \sup_{\theta \in W} P_{H_0}(\text{rejecting } H_0)$

דוגמא: $H_0: \mu \leq \mu_0$, $H_1: \mu > \mu_0$, $N(\mu, \sigma^2)$
 $\alpha = \sup_{\theta \in W} P(\bar{X} > C) = 1 - \Phi\left(\frac{C - \mu_0}{\sigma/\sqrt{n}}\right)$
ההסתברות לטעות מסוג I היא הכי גדולה כאשר $\mu = \mu_0$.
מבחן יחס נראות מוכלל: $0 \leq \Lambda(x) \leq 1$

לא בעל עוצמה מקסימאלית \rightarrow **סטטיסטי**
 $\Lambda(x) = \frac{\sup_{\theta \in W^c} f_\theta(\bar{x})}{\sup_{\theta \in W} f_\theta(\bar{x})}$
המבחן: דחייה- $\Lambda(x) \leq k_\alpha$
הערה: במבחן יחס נראות מציבים אנ"מ במכנה. מבחן י"מ מוכלל המונה והמכנה מתחלקים (לעומת ניימן-פירסן) ולכן גם האי שוויון.

מ"מ"מ מהתפלגות ברנולי:
 $H_0: p = p_0$, $H_1: p = p_1$, $Ber(p)$
 $\lambda(x) = \left(\frac{p_1(1-p_0)}{p_0(1-p_1)}\right)^x \left(\frac{1-p_1}{1-p_0}\right)^n > k_\alpha$
אם $p_0 < p_1$ דחייה- $\sum X_i > C_\alpha$
אם $p_1 < p_0$ דחייה- $\sum X_i < C_\alpha$
דוגמא: $\alpha = 0.05$, $n = 10$, $p_0 = 1/2$, $p_1 = 3/4$
מציאת אזור הדחייה: $P_{H_0}(X=10) + P(X=9) < 0.05$
 $+ P_{H_0}(X=8) > 0.05$
לא נכניס את-8 לאזור הדחייה. $R = \{9, 10\}$.
חישוב τ_α : $P(X=10) + P(X=9) + \tau_\alpha P(X=8) = 0.05$

התפלגות האימפוטטית של י"מ מוכלל:

$\chi^2(r) = -2 \log \Lambda \left(\frac{\lambda}{\lambda_0} \right)$
 $\lambda = \frac{\sum_{i=1}^n x_i}{n}$
 $\Lambda(x) \leq k_\alpha \Leftrightarrow \lambda \geq C_\alpha = \chi^2_{(r-1), \alpha}$
דוגמא: $H_0: \lambda = 1$, $H_1: \lambda \neq 1$, $X_i \sim \text{Pois}(\lambda)$
 $\Lambda = \frac{\prod_{i=1}^n e^{-\lambda_0} \lambda_0^{x_i} / x_i!}{\prod_{i=1}^n e^{-\bar{x}} \bar{x}^{x_i} / x_i!} = e^{-n(\lambda_0 - \bar{x})} \left(\frac{\lambda_0}{\bar{x}}\right)^{\sum x_i} < k_\alpha$
 $\Rightarrow -2(-n(\lambda_0 - \bar{x}) + \sum x_i (\ln \lambda_0 - \ln \bar{x})) > C_\alpha = \chi^2_{(r-1), \alpha}$

טיב התאמה: **למשתנה K קטגוריות בהסתברויות:** p_1, \dots, p_k
 $\sum p_j = 1$
מספר תצפיות בקטגוריה i: X_i
מספר תצפיות בקטגוריה j: X_j

בדיקת ההשערות: $H_0: \bar{p} = \bar{p}_0$, $H_1: \bar{p} \neq \bar{p}_0$
 $E(X_j) = np_{j0}$; $H_0: \bar{p}_0 = (p_{10}, \dots, p_{k0})$
הערה: $E_j = np_{j0} < 5$ מאחדים קטגוריות.

קטגוריה	A_k	...	A_2	A_1
סכינות	X_k	...	X_2	X_1
סכינות	np_{k0}	...	np_{20}	np_{10}

הערה: $\Lambda(x) = \prod \left(\frac{np_{j0}}{X_j}\right)^{X_j}$
 $\Lambda^* = 2 \sum x_i \ln \left(\frac{x_j}{np_{j0}}\right) \sim \chi^2_{(k-1)}$

דוגמא: האם הקובייה הוגנת?
התבאר 1 שבת 37 ניסויים

1	2	3	4	5	6
37	41	30	27	32	33

 $n = 200$, $1 \leq i \leq 6$
 $H_0: \forall i p_i = 1/6$, $H_1: \exists i p_i \neq 1/6$
המונה של Λ : $P_{H_0}(X_i = 37, \dots, X_6 = 33) = \left(\frac{1}{6}\right)^{37} \dots \left(\frac{1}{6}\right)^{33}$

המכנה של Λ : יש למצוא אנ"מים $\hat{p}_i = \frac{X_i}{200}$
 $\Lambda = \frac{(1/6)^{37} \dots (1/6)^{33}}{(37/200)^{37} \dots (33/200)^{33}} = \prod \left(\frac{200 - 1/6}{X_i}\right)^{X_i}$
1 פחות הסכום של האחרים.
המבחן של פירסון: סטטיסטי מבחן לבדיקת טיב התאמה של המדגם למודל הסתברותי: $X_p^2 = \sum \frac{(X_j - np_{j0})^2}{np_{j0}}$
מספיק גדול, אם H_0 נכונה אז: $X_p^2 \sim \chi^2_{(k-1)}$
הערה: גם כאן מאחדים קטגוריות בהן $E_j < 5$.
דוגמא: האם התפלגות גאומטרית?

$H_0: X \sim \text{Geo}(1/2)$, $H_1: \text{else}$, $p_{j0} = P_{H_0}(X = j) = \frac{1}{2^j}$
דוגמא: האם התפלגות נורמאלית?
אמידת התוחלת והשונות ע"י אנ"מ: מחלישים בהתאם להשערה, למשל: $\hat{\mu} = 76$, $\hat{\sigma}^2 = 12.72^2$
 $[a_j, a_{j+1}]: \hat{p}_j = \Phi\left(\frac{a_{j+1} - \hat{\mu}}{\hat{\sigma}}\right) - \Phi\left(\frac{a_j - \hat{\mu}}{\hat{\sigma}}\right)$
הערה חשובה: היה צורך לאמוד פרמטרים גם תחת H_0 ולכן מבאדים ד"ח. עבור אמידת r , d : "k-1-r".
טנסורמצייה:

$Y = g(x)$, $f_Y(y) = f_X(g^{-1}(y)) \cdot \left|\frac{\partial g^{-1}(y)}{\partial y}\right|$
 $X = \frac{1}{\theta} \ln \frac{1}{1 - e^{-Y}}$, $Y = -\ln(x)$, $Y \sim \exp\left(\frac{1}{\theta}\right)$
 $g^{-1}(Y) = e^{-Y} = X$, $\frac{\partial g^{-1}(Y)}{\partial Y} = -e^{-Y}$

בדיקת אי-תלות:

בדיקת קשר בין שני משתנים קטגוריים. **A**-קטגוריות השורה, **B**-קטגוריות העמודה. **הנתונים מסוכמים בטבלת שכחיות:**

$H_0: P(A_i \cap B_j) = P(A_i)P(B_j) \forall i, j$, $H_1: \text{else}$
דרג פיתרון: מחשבים מתי השכיחות הצפויה בכל תא בהנחה שהשערת האפס נכונה. ובונים טבלת שכחיות.
 $\hat{p}(A_i) = \frac{X_{i.}}{n}$, $\hat{p}(B_j) = \frac{X_{.j}}{n}$
 $E_{H_0}(X_{ij}) = n\hat{p}(A_i \cap B_j) = \frac{X_{i.} X_{.j}}{n}$

סטטיסטי: $X_p^2 = \sum \sum \frac{(X_{ij} - X_{i.} X_{.j} / n)^2}{X_{i.} X_{.j} / n}$
המבחן: דחייה- $X_p^2 > \chi^2_{(r-1)(c-1), \alpha}$
מספר קטגוריות שורה/עמודה: $r \times c$
חישוב Pval: $Pvalue = P(\chi^2_{(r-1)(c-1)} > X_p^2)$
נות: $(1 - \alpha_1) < Pval < (1 - \alpha_2)$, α_1, α_2 - ההסת' שמופיעות בשורה העליונה.

דוגמא- טיב התאמה עם כופלי לנרנז:
 $H_0: X \sim \text{Multi}(200, p_1, 3p_1, p_3, 0.5p_3, p_5, p_6)$
 $L = \frac{200!}{x_1! \dots x_6!} p_1^{x_1} (3p_1)^{x_2} p_3^{x_3} (0.5p_3)^{x_4} p_5^{x_5} p_6^{x_6}$
 $C = C + 3^{x_2} 0.5^{x_4} p_1^{(x_1+x_2)} p_3^{(x_3+x_4)} p_5^{x_5} p_6^{x_6}$
 $\ln(L) = C + (x_1 + x_2) \ln(p_1) + (x_3 + x_4) \ln(p_3) + x_5 \ln(p_5) + x_6 \ln(p_6) + \lambda(-4p_1 + 1.5p_3 + p_5 + p_6)$

$\frac{\partial \ln(L)}{\partial p_1} = \frac{x_1 + x_2}{p_1} - 4\lambda \rightarrow \hat{p}_1 = \frac{x_1 + x_2}{4\lambda}$
 $\hat{p}_3 = \frac{x_3 + x_4}{4\lambda}$, $\hat{p}_5 = \frac{x_5}{\lambda}$, $\hat{p}_6 = \frac{x_6}{\lambda}$, $\lambda = n = 200$
חישוב סטטיסטי פירסון:

n	6	5	4	3	2	1
200	26	25	25	40	64	20
	0.13	0.12	0.11	0.22	0.31	0.10
200	26	25	21.6	43.4	63	21

$X_p^2 = 1/21 + 1/63 + 11.56/43.4 + 11.56/21.6$
אמדנו 3 פרמטרים (אחרון נקבע לפי האחרים) ולכן: $k = 1 - r = 6 - 1 - 3 = 2$.
דוגמא- העדפת מוצר: 100 איש נשאלו בסקר מוצר מועדף מתוך-2. $H_0: \alpha = 0.05$. $p = 1/2$. $r = 2$.
 $X_j \sim \text{Bin}(100, p) \square N(100, p, 100pq)$
עוצמה: $H_0 \square N(50, 5^2)$, $X \square N(60, 24)$

$\pi = P_{p=0.6}(|Z| > z_{1-\alpha/2}) = 1 - P(|Z| \leq 1.96) = 1 - P\left(-1.96 < \frac{\sum X_i - 50}{5} < 1.96\right) = 1 - P\left(\frac{-1.96 \cdot 5 + 50 - 60}{\sqrt{24}} < \sum X_i - 60 < \frac{1.96 \cdot 5 + 50 - 60}{\sqrt{24}}\right) = 1 - P(-4.041 < z < 4.041) = 1 - \Phi(-4.041) + \Phi(4.041) = 0.516$

חישוב Pvalue בהשערה דו-צדדית: לוחקים את הסטטיסטי בערך מוחלט: $|T|$ (ערך חיובי). ובודקים את ההסת' ליפול באזורי הדחייה:
 $Pvalue = P_{H_0}(|t_n| > |T|) + P_{H_0}(|t_n| < -|T|) = 2 \cdot P_{H_0}(|t_n| > |T|) = 2 \cdot (1 - P(t_n < |T|))$
חישוב Pvalue בהשערה חד-צדדית: $H_1: p > p_0$ $Pval = P(t_n > T) = \frac{1}{2} Pval(\text{duz})$
 $H_1: p < p_0$ $Pval = P(t_n < T) = 1 - \frac{1}{2} Pval(\text{duz})$

בדיקת השערות על החתוך:

$H_0: \beta_0 = \beta_0^0$ vs $H_{1a}: \beta_0 > \beta_0^0$
 $H_0: \beta_0 = \beta_0^0$ vs $H_{1b}: \beta_0 < \beta_0^0$
 $H_0: \beta_0 = \beta_0^0$ vs $H_{1c}: \beta_0 \neq \beta_0^0$

סטטיסטי המבחן:

$$T = \frac{\hat{\beta}_0 - \beta_0^0}{\hat{\sigma} \sqrt{\sum X_i^2 / n S_{XX}}} \sim t_{(n-2)}$$

אם ס ידועה:

$$\frac{\hat{\beta}_0 - \beta_0^0}{\sigma \sqrt{\sum X_i^2 / n S_{XX}}} \sim N(0,1)$$

דוחים:
 A: $T > t_{(n-2), 1-\alpha}$
 B: $T < -t_{(n-2), 1-\alpha}$
 C: $T > t_{(n-2), 1-\alpha/2}$ or $T < -t_{(n-2), 1-\alpha/2}$

P-value:
 A: $P(T \geq t)$
 B: $P(T \leq -t)$
 C: $P(T \geq |t|)$

ר"ס לחתוך:
 $\hat{\beta}_0 \pm \hat{\sigma} \sqrt{\frac{\sum X_i^2}{n S_{XX}}}$

השונות הבלתי מוסברת:

$$\hat{\sigma}^2 = \frac{(1-R^2)S_{YY}}{n-2} = \frac{n-1}{n-2} \sqrt{1-R^2} S_Y$$

הסטייה הטיפוסית מקו הרגרסיה

הסטייה מהקו של ערך \bar{Y} בהינתן ערך \bar{X} :
 $R < 1$: הסטייה מהקו קטנה מהסטייה הטיפוסית של \bar{Y} .
 $|R|=1$: הסטייה מהקו שווה לאפס.
 $R=0$: הסטייה מהקו (השונות במודל קטנה ככל ש- R^2 גדל).

בדיקת השערות ורווחי סמך:

בדיקת השערות על השיפוע:

$H_0: \beta_1 = \beta_1^0$ vs $H_{1a}: \beta_1 > \beta_1^0$
 $H_0: \beta_1 = \beta_1^0$ vs $H_{1b}: \beta_1 < \beta_1^0$
 $H_0: \beta_1 = \beta_1^0$ vs $H_{1c}: \beta_1 \neq \beta_1^0$

תוצאות חשבוניות לבניית סטטיסטי המבחן:

$$E(\hat{\beta}_1) = \beta_1, \text{Var}(\hat{\beta}_1) = \hat{\sigma}^2 / S_{XX}$$

טענה:
 $(n-2)\hat{\sigma}^2 / \sigma^2 \sim \chi^2_{(n-2)}$

טענה:
 $\hat{\beta}_1$ מתפלג נורמלית ובי"ב- $\hat{\sigma}^2$.

סטטיסטי המבחן:
 $T = \frac{\hat{\beta}_1 - \beta_1^0}{\hat{\sigma} / \sqrt{S_{XX}}} \sim t_{(n-2)}$

אם ס ידועה:
 $\frac{\hat{\beta}_1 - \beta_1^0}{\sigma / \sqrt{S_{XX}}} \sim N(0,1)$

דוחים:
 A: $T > t_{(n-2), 1-\alpha}$
 B: $T < -t_{(n-2), 1-\alpha}$
 C: $T > t_{(n-2), 1-\alpha/2}$ or $T < -t_{(n-2), 1-\alpha/2}$

P-value:
 A: $P(T \geq t)$
 B: $P(T \leq -t)$
 C: $P(T \geq |t|)$

ר"ס לשיפוע (ר"ס $1-\alpha$):
 $\hat{\beta}_1 \pm \frac{\hat{\sigma}}{\sqrt{S_{XX}}} t_{1-\alpha/2, (n-2)}$

מקרה פרטי:
 $H_0: \beta_1 = 0, H_{1c}: \beta_1 \neq 0$

$$T^2 = \frac{\hat{\beta}_1^2 S_{XX}}{\hat{\sigma}^2} = \frac{MSR}{MSE} \sim F_{(1, n-2)}$$

זהו הסטיסטי בעמוד F ב-ANOVA.

הגדרת שגיאה:
 $e_i = Y_i - \hat{Y}_i = Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i$

תכונות חשובות:
 $\sum e_i = 0, \sum X_i e_i = 0$

$e_i: e_i \neq \epsilon_i$. מרחק התצפית מקו הרגרסיה.
 e_i - מרחק התצפית מהקו האמיתי.
 הערך המנובא: לכל הצפייה - $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$
 השאריות: לכל הצפייה - $e_i = Y_i - \hat{Y}_i$

אמידת השונות במודל:
 $(Y|X=x) \sim N(\beta_0 + \beta_1 x, \sigma^2)$

אמידת σ^2 על-סמך שונות השאריות:

$$SSE = \sum (e_i - \bar{e})^2 = \sum (Y_i - \hat{Y}_i)^2$$

$$\hat{\sigma}^2 = \frac{SSE}{n-2} = \frac{\sum (Y_i - \beta_0 - \beta_1 X_i)^2}{n-2}$$

טענה:
 $E(\hat{\sigma}^2) = \sigma^2$ (אמד חסר הטייה).

אמידת שונות האר"פ:
 $Var(\hat{\beta}_0) = \hat{\sigma}^2 \sum X_i^2 / n S_{XX}, Var(\hat{\beta}_1) = \hat{\sigma}^2 / S_{XX}$

אומדי נראות מירבית:
טענה: תחת הנחת הנורמליות $\beta_0, \beta_1, \sigma^2$ הם "אנ"מים ל- $\beta_0, \hat{\beta}_1, \hat{\sigma}^2$

פירוק סכומי הריבועים:
 $SST = SSR + SSE$

SSR - השונות המוסברת, SSE - אינה מוסברת.

מקדם המתאם הליניארי:
 זהו מדד לתרומת הריבועי מקדם המתאם הליניארי. R^2 האומד לריבועי מקדם המתאם הליניארי. זהו % השונות המוסברת של \bar{Y} ע"י המודל.

$$0 \leq R^2 \leq 1, R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST}$$

מקדם המתאם:
 $-1 \leq \rho_{X,Y} = \frac{Cov(X,Y)}{\sigma_X \sigma_Y} \leq 1$

עבור X, Y ב"ת: $\rho_{X,Y} = 0$ (ענן חסר צורה).
הערה: לא גורר X, Y ב"ת!
 עבור X, Y המקיימים: $Y = \beta_0 + \beta_1 X$
 $Cov(X, Y) = \beta_1 \sigma_X^2 = \begin{cases} 1 & \beta_1 > 0 \\ -1 & \beta_1 < 0 \end{cases}$
 $\rho_{X,Y} = \beta_1 \frac{\sigma_X}{\sigma_X \sigma_Y} = \begin{cases} 1 & \beta_1 > 0 \\ -1 & \beta_1 < 0 \end{cases}$

אומד למקדם המתאם:
 $R = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2} \sqrt{\sum (Y_i - \bar{Y})^2}} = \frac{S_{XY}}{\sqrt{S_{XX} S_{YY}}}$

תכונות:
 1. ערך R סימטרי עבור X ו- Y .
 2. ערך R לא תלוי בהיחידות המדידה של X, Y .
 3. $R \approx 0$ מעיד על חוסר קשר ליניארי (ייתכן שישנו קשר שאינו ליניארי).
 4. כאשר הקשר ליניארי, $|R|$ מודד את חוזקו.
 5. יכול להתקבל R גבוה גם כאשר הקשר לא ליניארי.
 6. R רגיש לתצפיות חריגות (מודל הרגרסיה מניח שאין תצפיות חריגות).

הערה: לא ניתן להסתמך על R^2 גבוה לקביעת ליניאריות. ניתן להסתמך על נמוך לקביעת חוסר ליניאריות.

רגרסיה ליניארית פשוטה:
 בעזרת מודלים של רגרסיה ניתן לחקור את הקשר בין שני משתנים קשורים באופן לא דטרמיניסטי זוהי הרחבה של המודל הדטרמיניסטי הליניארי - $Y = \beta_0 + \beta_1 X$
 למודל ליניארי הסתברותי אשר מאפשר לנובא את הערך של Y על-סמך הערך X .
הנחת המודל הליניארי
 ככל ש- σ^2 גדולה יותר, התצפיות יותר מפורזות. $E(Y|X=x) = \beta_0 + \beta_1 x + \epsilon, \epsilon \sim N(0, \sigma^2)$ ומתרחקות מהקו.

יודעים את X ומנחשים את Y בצורה הטובה ביותר (לא Y נקבע בודאכתי כשנזן "רעש" מבחינה הסתברותית).
 מתוך המנב רוצים לאמוד את β_0, β_1 כדי לנבא את Y בצורה טובה.

$E(Y|X=x) = E(\beta_0 + \beta_1 X + \epsilon) = \beta_0 + \beta_1 X$
 $Var(Y|X=x) = Var(\beta_0 + \beta_1 X + \epsilon) = Var(\epsilon) = \sigma^2$

Y - משתנה מוסבר. X - משתנה מסביר. לכל Y, ההתפלגות תיאור גרפי של המודל:

המונחים של Y המותנית של Y היא בהינתן X היא נורמלית

השונות של Y בהינתן X קבועה ב-X והיא עולה כמכונקציה של X

משמעות σ^2 : ככל שהשונות יותר קטנה, נלפח ההתצפיות יהיו קרובות לישר הרגרסיה האמיתי.

אמידת מקדמי הרגרסיה:
 $\beta_0, \beta_1, \epsilon \sim N(0, \sigma^2)$

מדגם מקרי:
 $Y_i = \beta_0 + \beta_1 X_i + \epsilon_i, (X_1, Y_1), \dots, (X_n, Y_n)$

אומדי ריבועים ממוזגים: הישר המביא למינימום את סכום ריבועי המרחקים האנכיים בין כל נקודה לישר.

אד"פ:
 $\hat{\beta}_0, \hat{\beta}_1$ ערכי b_0, b_1 המביאים למינימום את מציאת אר"פ ע"י המשוואות הנורמליות:

$$1) \frac{\partial g(b_0, b_1)}{\partial b_0} = -2 \sum (Y_i - (b_0 + b_1 X_i)) = 0$$

$$2) \frac{\partial g(b_0, b_1)}{\partial b_1} = -2 \sum X_i (Y_i - (b_0 + b_1 X_i)) = 0$$

פיתרון המשוואות הנורמליות:
 $b_0 = \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$
 $b_1 = \hat{\beta}_1 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{S_{XY}}{S_{XX}}$

נוסאות לאמידת קו הרגרסיה:
 $S_{XY} = \sum (X_i - \bar{X})(Y_i - \bar{Y}) = \sum (X_i - \bar{X}) Y_i$
 $S_{XX} = \sum (X_i - \bar{X})^2 = \sum (X_i - \bar{X}) X_i = \sum X_i^2 - n \bar{X}^2$
 $S_{YY} = \sum (Y_i - \bar{Y})^2 = \sum (Y_i - \bar{Y}) Y_i = \sum Y_i^2 - n \bar{Y}^2$
 $S_X^2 = S_{XX} / n - 1, S_Y^2 = S_{YY} / n - 1$

האומד לישר הרגרסיה:
 $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X$

שאלות שניתן לענות עליהן:
 - בהינתן X מסוים, מהו ה- Y המצופה?
פיתרון: ערך הנקודה Y על קו הרגרסיה.
 - בהינתן הפרש של 1 ב- X מהו ההפרש של המצופה ב- Y ?
פיתרון: יש לבחור 4 ערכי X שעבורם נמדוד את הקו.
 - תיאור החתוך: הערך המצופה כאשר $X=0$ (אם $X=0$ לא בטוח התצפיות זוהי אקסטרפולציה)
אקסטרפולציה: ניבוי ערכי Y עבור ערכי X שאינם בטוח תכונות האר"פ:
למציאת אר"פ אין חסרי הטייה: $E(\hat{\beta}_0) = \beta_0, E(\hat{\beta}_1) = \beta_1$
עקבים: $Var(\hat{\beta}_0) = \sigma^2 \frac{\sum X_i^2}{n S_{XX}}, Var(\hat{\beta}_1) = \sigma^2 \frac{1}{S_{XX}}$
 וגם אנ"מים.
 ככל ששונות ה- X שבתצפיות יותר גדולה (המרחק ביניהם), יש יותר ביטחון בשיפוע הקו שמתקבל על-ידים.
דוגמה: יש לבחור 4 ערכי X שעבורם נמדוד את הקו.
פיתרון: נרצה X -ים שייטנו S_{XX} מקסימאלי כדי ש- $Var(\hat{\beta}_1) = \sigma^2 / S_{XX}$ יהיה מינימאלי.
 כאשר לא ידוע שהמודל הוא ליניארי, נבחר תצפיות יותר מפורזות:

האמדים לחתוך ולשיפוע מתפלגים נורמלית:

$$\hat{\beta}_0 \sim N\left(\beta_0, \sigma^2 \frac{\sum X_i^2}{n S_{XX}}\right), \hat{\beta}_1 \sim N\left(\beta_1, \frac{\sigma^2}{S_{XX}}\right)$$

$Cov(\hat{\beta}_0, \hat{\beta}_1) = -\sigma^2 \frac{\bar{X}}{S_{XX}}, Cov(\hat{\beta}, \bar{Y}) = 0$
 $\forall i: Cov(\hat{\beta}_0, e_i) = 0, Cov(\hat{\beta}_1, e_i) = 0$

ניתן להציג את האמד לחתוך בצורה הבאה:
 $\hat{\alpha} = \sum c_i Y_i, c_i = \frac{1}{n} \bar{X} - \frac{\bar{X} \bar{X}}{S_{XX}}$

אומדי נראות מירבית:
טענה: תחת הנחת הנורמליות $\beta_0, \beta_1, \sigma^2$ הם "אנ"מים ל- $\beta_0, \hat{\beta}_1, \hat{\sigma}^2$

פירוק סכומי הריבועים:
 $SST = SSR + SSE$

SSR - השונות המוסברת, SSE - אינה מוסברת.

מקדם המתאם הליניארי:
 זהו מדד לתרומת הריבועי מקדם המתאם הליניארי. R^2 האומד לריבועי מקדם המתאם הליניארי. זהו % השונות המוסברת של \bar{Y} ע"י המודל.

$$0 \leq R^2 \leq 1, R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST}$$

מקדם המתאם:
 $-1 \leq \rho_{X,Y} = \frac{Cov(X,Y)}{\sigma_X \sigma_Y} \leq 1$

עבור X, Y ב"ת: $\rho_{X,Y} = 0$ (ענן חסר צורה).
הערה: לא גורר X, Y ב"ת!
 עבור X, Y המקיימים: $Y = \beta_0 + \beta_1 X$
 $Cov(X, Y) = \beta_1 \sigma_X^2 = \begin{cases} 1 & \beta_1 > 0 \\ -1 & \beta_1 < 0 \end{cases}$
 $\rho_{X,Y} = \beta_1 \frac{\sigma_X}{\sigma_X \sigma_Y} = \begin{cases} 1 & \beta_1 > 0 \\ -1 & \beta_1 < 0 \end{cases}$

אומד למקדם המתאם:
 $R = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2} \sqrt{\sum (Y_i - \bar{Y})^2}} = \frac{S_{XY}}{\sqrt{S_{XX} S_{YY}}}$

תכונות:
 1. ערך R סימטרי עבור X ו- Y .
 2. ערך R לא תלוי בהיחידות המדידה של X, Y .
 3. $R \approx 0$ מעיד על חוסר קשר ליניארי (ייתכן שישנו קשר שאינו ליניארי).
 4. כאשר הקשר ליניארי, $|R|$ מודד את חוזקו.
 5. יכול להתקבל R גבוה גם כאשר הקשר לא ליניארי.
 6. R רגיש לתצפיות חריגות (מודל הרגרסיה מניח שאין תצפיות חריגות).

הערה: לא ניתן להסתמך על R^2 גבוה לקביעת ליניאריות. ניתן להסתמך על נמוך לקביעת חוסר ליניאריות.

אמידת מקדמי הרגרסיה:
 $\beta_0, \beta_1, \epsilon \sim N(0, \sigma^2)$

מדגם מקרי:
 $Y_i = \beta_0 + \beta_1 X_i + \epsilon_i, (X_1, Y_1), \dots, (X_n, Y_n)$

אומדי ריבועים ממוזגים: הישר המביא למינימום את סכום ריבועי המרחקים האנכיים בין כל נקודה לישר.

אד"פ:
 $\hat{\beta}_0, \hat{\beta}_1$ ערכי b_0, b_1 המביאים למינימום את מציאת אר"פ ע"י המשוואות הנורמליות:

$$1) \frac{\partial g(b_0, b_1)}{\partial b_0} = -2 \sum (Y_i - (b_0 + b_1 X_i)) = 0$$

$$2) \frac{\partial g(b_0, b_1)}{\partial b_1} = -2 \sum X_i (Y_i - (b_0 + b_1 X_i)) = 0$$

פיתרון המשוואות הנורמליות:
 $b_0 = \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$
 $b_1 = \hat{\beta}_1 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{S_{XY}}{S_{XX}}$

נוסאות לאמידת קו הרגרסיה:
 $S_{XY} = \sum (X_i - \bar{X})(Y_i - \bar{Y}) = \sum (X_i - \bar{X}) Y_i$
 $S_{XX} = \sum (X_i - \bar{X})^2 = \sum (X_i - \bar{X}) X_i = \sum X_i^2 - n \bar{X}^2$
 $S_{YY} = \sum (Y_i - \bar{Y})^2 = \sum (Y_i - \bar{Y}) Y_i = \sum Y_i^2 - n \bar{Y}^2$
 $S_X^2 = S_{XX} / n - 1, S_Y^2 = S_{YY} / n - 1$

האומד לישר הרגרסיה:
 $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X$

שאלות שניתן לענות עליהן:
 - בהינתן X מסוים, מהו ה- Y המצופה?
פיתרון: ערך הנקודה Y על קו הרגרסיה.
 - בהינתן הפרש של 1 ב- X מהו ההפרש של המצופה ב- Y ?
פיתרון: יש לבחור 4 ערכי X שעבורם נמדוד את הקו.
 - תיאור החתוך: הערך המצופה כאשר $X=0$ (אם $X=0$ לא בטוח התצפיות זוהי אקסטרפולציה)
אקסטרפולציה: ניבוי ערכי Y עבור ערכי X שאינם בטוח תכונות האר"פ:
למציאת אר"פ אין חסרי הטייה: $E(\hat{\beta}_0) = \beta_0, E(\hat{\beta}_1) = \beta_1$
עקבים: $Var(\hat{\beta}_0) = \sigma^2 \frac{\sum X_i^2}{n S_{XX}}, Var(\hat{\beta}_1) = \sigma^2 \frac{1}{S_{XX}}$
 וגם אנ"מים.
 ככל ששונות ה- X שבתצפיות יותר גדולה (המרחק ביניהם), יש יותר ביטחון בשיפוע הקו שמתקבל על-ידים.
דוגמה: יש לבחור 4 ערכי X שעבורם נמדוד את הקו.
פיתרון: נרצה X -ים שייטנו S_{XX} מקסימאלי כדי ש- $Var(\hat{\beta}_1) = \sigma^2 / S_{XX}$ יהיה מינימאלי.
 כאשר לא ידוע שהמודל הוא ליניארי, נבחר תצפיות יותר מפורזות:

Regression Statistics

Multiple R	R
R Square	R ²
Adjusted R Square	
Standard Error	$\hat{\sigma}$
Observations	n

ANOVA Table

Source of Variation	Degrees of Freedom	Sum of Squares	Mean Squares	F	Pvalue
רגרסיה	1	SSR	MSR=SSR	MSR/MSE	P(F>f)
שאריות	n-2	SSE	MSE=SSE/(n-2)		
Total	n-1	SST			

$H_0: \beta_1 = 0$ vs $H_1: \beta_1 \neq 0$
סטטיסטי המבחן לבדיקת ההשערה:
 $T = \frac{\hat{\beta}_1}{\hat{\sigma} / \sqrt{S_{XX}}} \sim t_{(n-2)}$
Pvalue עדות זקה לכך שיש קשר בין X ל- Y .

ANOVA Table

Variable	Parameter Estimate	Standard Error	T for $H_0: \beta_0=0, H_1: \beta_0 \neq 0$	Pvalue
חותך	$\hat{\beta}_0$	$\hat{\sigma}_{\hat{\beta}_0} = \hat{\sigma} \sqrt{\frac{\sum X_i^2}{n S_{XX}}}$	$\frac{\hat{\beta}_0 - \beta_0^0}{\hat{\sigma}_{\hat{\beta}_0}}$	
שיפוע	$\hat{\beta}_1$	$\hat{\sigma}_{\hat{\beta}_1} = \hat{\sigma} / \sqrt{S_{XX}}$	$\frac{\hat{\beta}_1 - \beta_1^0}{\hat{\sigma}_{\hat{\beta}_1}} = \sqrt{F}$	

Pvalue בשורה של השיפוע שווה ל- $Pvalue$ ב-ANOVA.

ר"ס לתוחלת של Y בהינתן X:
אמידת התוחלת של Y בהינתן X:
אמידת $E(Y|X=x_0) = \beta_0 + \beta_1 x_0 = \eta(x_0)$
ע"י: $\hat{\eta}(x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_0$

התפלגות האמד:
חסר הטייה $E(\hat{\eta}(x_0)) = \eta(x_0)$
טענה: ר"ס צר ביותר יתקבל עבור $x_0 = \bar{X}$.
רווח תחזית:
 בניית רווח עבור הצפייה חדשה y_0 בהינתן x_0 , שמרכזו על קו הרגרסיה והוא סימטרי סביבו.
הנחה: $(Y_0|X=x_0) \sim N(\beta_0 + \beta_1 x_0, \sigma^2)$

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{X})^2}{S_{XX}}}$$

$$P(Y_0 \in PI) = 1 - \alpha$$
הערה: כאשר $n \rightarrow \infty$, ר"ס קטן והופך לנקודה, אבל אורך רווח תחזית שואף ל: $2 \cdot z_{1-\alpha/2} \cdot \sigma$.
הערה: תמיד הר"ס מוכל ברווח תחזית. ככל שמרחקים מ- \bar{X} דיוק ר"ס פחות טוב, ואילו הרווח תחזית נשאר זהה (הקווים כמעט ישרים).

הנחות לבניית רווח תחזית:
 - קשר ליניארי.
 - שונות סטיות קבועה לכל X .
 - אין תצפיות חריגות.
 - התפלגות הסטיות נורמלית.

ANOVA Table

Source of Variation	Degrees of Freedom	Sum of Squares	Mean Squares	F	Pvalue
רגרסיה	1	SSR	MSR=SSR	MSR/MSE	P(F>f)
שאריות	n-2	SSE	MSE=SSE/(n-2)		
Total	n-1	SST			

$H_0: \beta_1 = 0$ vs $H_1: \beta_1 \neq 0$
סטטיסטי המבחן לבדיקת ההשערה:
 $T = \frac{\hat{\beta}_1}{\hat{\sigma} / \sqrt{S_{XX}}} \sim t_{(n-2)}$
Pvalue עדות זקה לכך שיש קשר בין X ל- Y .

ANOVA Table

Variable	Parameter Estimate	Standard Error	T for $H_0: \beta_0=0, H_1: \beta_0 \neq 0$	Pvalue
חותך	$\hat{\beta}_0$	$\hat{\sigma}_{\hat{\beta}_0} = \hat{\sigma} \sqrt{\frac{\sum X_i^2}{n S_{XX}}}$	$\frac{\hat{\beta}_0 - \beta_0^0}{\hat{\sigma}_{\hat{\beta}_0}}$	
שיפוע	$\hat{\beta}_1$	$\hat{\sigma}_{\hat{\beta}_1} = \hat{\sigma} / \sqrt{S_{XX}}$	$\frac{\hat{\beta}_1 - \beta_1^0}{\hat{\sigma}_{\hat{\beta}_1}} = \sqrt{F}$	

Pvalue בשורה של השיפוע שווה ל- $Pvalue$ ב-ANOVA.

ר"ס לתוחלת של Y בהינתן X:
אמידת התוחלת של Y בהינתן X:
אמידת $E(Y|X=x_0) = \beta_0 + \beta_1 x_0 = \eta(x_0)$
ע"י: $\hat{\eta}(x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_0$

התפלגות האמד:
חסר הטייה $E(\hat{\eta}(x_0)) = \eta(x_0)$
טענה: ר"ס צר ביותר יתקבל עבור $x_0 = \bar{X}$.
רווח תחזית:
 בניית רווח עבור הצפייה חדשה y_0 בהינתן x_0 , שמרכזו על קו הרגרסיה והוא סימטרי סביבו.
הנחה: $(Y_0|X=x_0) \sim N(\beta_0 + \beta_1 x_0, \sigma^2)$

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{X})^2}{S_{XX}}}$$

$$P(Y_0 \in PI) = 1 - \alpha$$
הערה: כאשר $n \rightarrow \infty$, ר"ס קטן והופך לנקודה, אבל אורך רווח תחזית שואף ל: $2 \cdot z_{1-\alpha/2} \cdot \sigma$.
הערה: תמיד הר"ס מוכל ברווח תחזית. ככל שמרחקים מ- \bar{X} דיוק ר"ס פחות טוב, ואילו הרווח תחזית נשאר זהה (הקווים כמעט ישרים).

הנחות לבניית רווח תחזית:
 - קשר ליניארי.
 - שונות סטיות קבועה לכל X .
 - אין תצפיות חריגות.
 - התפלגות הסטיות נורמלית.

ANOVA Table

Source of Variation	Degrees of Freedom	Sum of Squares	Mean Squares	F	Pvalue
רגרסיה	1	SSR	MSR=SSR	MSR/MSE	P(F>f)
שאריות	n-2	SSE	MSE=SSE/(n-2)		
Total	n-1	SST			

$H_0: \beta_1 = 0$ vs $H_1: \beta_1 \neq 0$
סטטיסטי המבחן לבדיקת ההשערה:
 $T = \frac{\hat{\beta}_1}{\hat{\sigma} / \sqrt{S_{XX}}} \sim t_{(n-2)}$
Pvalue עדות זקה לכך שיש קשר בין X ל- Y .

ANOVA Table

Variable	Parameter Estimate	Standard Error	T for $H_0: \beta_0=0, H_1: \beta_0 \neq 0$	Pvalue
חותך	$\hat{\beta}_0$	$\hat{\sigma}_{\hat{\beta}_0} = \hat{\sigma} \sqrt{\frac{\sum X_i^2}{n S_{XX}}}$	$\frac{\hat{\beta}_0 - \beta_0^0}{\hat{\sigma}_{\hat{\beta}_0}}$	
שיפוע	$\hat{\beta}_1$	$\hat{\sigma}_{\hat{\beta}_1} = \hat{\sigma} / \sqrt{S_{XX}}$	$\frac{\hat{\beta}_1 - \beta_1^0}{\hat{\sigma}_{\hat{\beta}_1}} = \sqrt{F}$	

Pvalue בשורה של השיפוע שווה ל- $Pvalue$ ב-ANOVA.

ר"ס לתוחלת של Y בהינתן X:
אמידת התוחלת של Y בהינתן X:
אמידת $E(Y|X=x_0) = \beta_0 + \beta_1 x_0 = \eta(x_0)$
ע"י: $\hat{\eta}(x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_0$

התפלגות האמד:
חסר הטייה $E(\hat{\eta}(x_0)) = \eta(x_0)$
טענה: ר"ס צר ביותר יתקבל עבור $x_0 = \bar{X}$.
רווח תחזית:
 בניית רווח עבור הצפייה חדשה y_0 בהינתן x_0 , שמרכזו על קו הרגרסיה והוא סימטרי סביבו.
הנחה: $(Y_0|X=x_0) \sim N(\beta_0 + \beta_1 x_0, \sigma^2)$

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{X})^2}{S_{XX}}}$$

$$P(Y_0 \in PI) = 1 - \alpha$$
הערה: כאשר $n \rightarrow \infty$, ר"ס קטן והופך לנקודה, אבל אורך רווח תחזית שואף ל: $2 \cdot z_{1-\alpha/2} \cdot \sigma$.
הערה: תמיד הר"ס מוכל ברווח תחזית. ככל שמרחקים מ- \bar{X} דיוק ר"ס פחות טוב, ואילו הרווח תחזית נשאר זהה (הקווים כמעט ישרים).

הנחות לבניית רווח תחזית:
 - קשר ליניארי.
 - שונות סטיות קבועה לכל X .
 - אין תצפיות חריגות.
 - התפלגות הסטיות נורמלית.