

סיכומים למבחן בקורס סטטיסטיקה למדעי המחשב

סמסטר א' 9-2008 (ד"ר סהרון רוסט)

תוכן עניינים:

- הגדרות בסיסיות בהסתברות בדידה
- פרדוקס סימפסון
- ניתוחים ויזואליים של משתני מדידה מספריים
- תמצית מספרית של נתונים מספריים:
 - הגדרות: תמצית מספרית, סטטיסטי הסדר
 - שברונים ואחוזונים של התפלגות אמפירית
 - קריטריונים לבחירת תמציות
 - תמציות למיקום, פיזור, נטייה
- מטרת ההצגה הגרפית
- מידול מתמטי של קשרים בין משתנים – הגרסיה לינארית:
 - הקו החסין
 - קו הריבועים הפחותים
 - מדידת טיב התאמת קו הריבועים הפחותים לנתונים: מקדם המתאם של פירסון (r^2) ותכונותיו
 - ניתוח שאריות וטרנסי' ללינאריות
 - רגרסיה רב משתנית, קריטריון RSS
- משתנים מקריים רציפים:
 - פונ'י הסתברות מצטברת, פונ'י צפיפות
 - משתנה מקרי רציף
 - התפלגות משותפת מותנה של מספר מ"מ רציפים
 - תוחלת ושונות מ"מ רציפים
 - אחוזונים ושברונים של התפלגויות רציפות
- משפט הגבול המרכזי לקירוב נורמלי:
 - הגדרה
 - מתי הקירוב הנורמלי מתאים
- מבוא להסקה סטטיסטית
 - מושגי ייסוד באמידה
 - תכונות אומדים ואיכותם: הטיה, פיזור, MSE , עקיבות
- גישות ליצירת אומדים:
 - פונ'י נראות מקסימלית
 - אומד נראות מקסימלי ותכונותיו
- רווחי סמך:
 - רווחי סמך ומשמעותם
 - אינווריאנטיות רווחי סמך תחת טרנסי' מונוטונית
- בדיקת השערות:
 - מושגי ייסוד, סוגי השערות
 - רמת מובהקות, סוגי טעויות ועוצמה
- בחירת אזורי דחייה והלמה של ניימן-פירסון (NP)
 - הלמה של ניימן-פירסון
 - מבחנים בעלי עוצמה מקסימלית לפי NP
 - הכללת NP – מבחנים בעלי עוצמה מקסימלית במידה שווה (UMP)
- הסקה סטטיסטית בבעיות רגרסיה
- מבחנים לקשר בין 2 התפלגויות / מ"מ:
 - מבחנים לא מזווגים לשני מדגמים
 - הסקה במדגמים מזווגים
- הסקה על קשרים בין התפלגויות בדידות קטגוריאליות
 - מבחנים לשוויון פרופורציות
 - התפלגות חי בריבוע (χ^2):
 - הגדרה
 - רגרסיה מול χ^2
 - מבחן χ^2 של פירסון לאיכות התאמה
- נושאים נוספים:
 - השוואות מרובות
 - מבחנים סטטיסטיים לא-פרמטריים
 - אמידה בייסיאנית

הגדרות בסיסיות בהסתברות בדידה :

תוחלת :

בהינתן X מ"מ מהתפלגות F , ומרחב המדגם מקיים $\Omega \subset \mathbb{R}$, התוחלת: $E(X) = \sum_{x \in \Omega} xF(x)$. תכונות:

- א. לכל $a \in \mathbb{R}$ $E(aX) = aE(X)$.
- ב. אדיטיביות: $E(X_1) + E(X_2) = E(X_1 + X_2)$.
- ג. עבור $f(X) = aX + b$ פונ' לינארית, מתקיים: $E(f(X)) = aE(X) + b$.

שונות :

מידת ה"פיזור" של X : $var(X) = E[(X - E(X))^2] = E(X^2) - E(X)^2$. תכונות:

- א. לכל $a \in \mathbb{R}$ $var(aX) = a^2 var(X)$.
- ב. $var(X_1 + X_2) = var(X_1) + var(X_2) - 2cov(X_1, X_2)$. עבור מ"מ בלתי מתואמים: $cov(X_1, X_2) = 0$, כלומר, מתקיימת אדיטיביות תחת אי תלות. נוסחה ל- cov : $cov(X_1, X_2) = E[(X_1 - E(X_1)) \cdot (X_2 - E(X_2))]$.

מקדם המתאם :

מקדם המתאם (של פירסון): $-1 \leq \rho(X_1, X_2) = \frac{cov(X_1, X_2)}{\sqrt{var(X_1) \cdot var(X_2)}} \leq 1$.

אם $\rho = 0$ אזי לא קיים קשר לינארי בין שני המ"מ (בלתי תלויים לינארית). אם $\rho = 1$ קשורים לינארית, $\rho = -1$ קשורים לינארית בפונ' לינארית הפוכה.

דוגמאות למ"מ בדידים חשובים :

שונות $var(X)$	תוחלת $E(X)$	פונ' התפלגות	התפלגות
$p(1-p)$	p	$F(1) = p,$ $F(0) = 1-p$	ברנולי עם פרמטר p (לרוב מרחב מדגם פשוט: $\Omega = \{0,1\}$) $X \sim Bernoulli(p)$ סיפור: הסיכוי להצלחה בהטלת מטבע בודדת
$np(1-p)$	np	$F(X=k) = \binom{n}{k} p^k (1-p)^{n-k},$ $0 \leq k \leq n$	בינומי עם פרמטרים n, p $X \sim Bin(n, p)$ סיפור: הסיכוי ל- k עצים ב- n הטלות מטבע (p - סיכוי לעץ)
נשים לב כי אם $X_1, \dots, X_n \sim Bern(p)$ ובי"ת, אזי: $\sum_{i=1}^n X_i \sim Bin(n, p)$. מכאן גם ניתן לחשב את התוחלת והשונות לבינומי			
λ	λ	$F(X=k) = \frac{\lambda^k}{k!} \cdot e^{-\lambda},$ $k \geq 0$	פואסוני עם פרמטר λ $X \sim Pois(\lambda)$ סיפור: הסיכוי להתרחשות k אירועים בפרק זמן קבוע בקצב λ , כאשר מס' אירועים בכל פרק זמן אינו תלוי בזמנים אחרים
$\frac{1-p}{p^2}$	$\frac{1}{p}$	$F(X=k) = (1-p)^{k-1} \cdot p,$ $k \geq 1$	גיאומטרי עם פרמטר p $X \sim G(p)$ סיפור: הסיכוי שהעץ הראשון שנקבל יהיה בהטלה ה- k
$\frac{n \binom{D}{N} \left(\frac{1-D}{N}\right) (N-n)}{N-1}$	$\frac{nD}{N}$	$F(X=k) = \frac{\binom{D}{k} \binom{N-D}{n-k}}{\binom{N}{n}}$	היפרגיאומטרית עם פרמטרים N, D, n $X \sim HG(N, D, n)$ סיפור: מתוך אוכלוסיה בגודל N המכילה D פריטים מיוחדים ממנה שולפים n פריטים, הסיכוי שמתוכם k פריטים יהיו מיוחדים

נוסחה חשובה להתפלגות מותנית להחלפת סדר ההתניה: $P(X=F | Y=A) = P(Y=A | X=F) \cdot \frac{P(X=F)}{P(Y=A)}$

פרדוקס סימפסון :

פרדוקס סטטיסטי בו הצלחת קבוצת מחקר מסוימת נראית שונה כאשר מאחדים בין קבוצות. דוגמה שניתנה בשיעור: אחוז הקבלה של בנות לאוני נמוך מאחוז הקבלה של בנים, אך אם מסתכלים על כל פקולטה בנפרד מקבלים שבכל פקולטה אחוז הקבלה של הבנות גדול מאחוז הקבלה של הבנים. לכאורה מקבלים כאן פרדוקס, אך ניתן לראות שהנתונים מאפשרים זאת באמצעות משחק עם הנוסחאות (בייס, ההסתברות השלמה).

ניתוחים ויזואליים של משתני מדידה מספריים :

היסטוגרמה : מהתבוננות בהיסטוגרמה ניתן לדלות מידע מתוך :

- מספר השיאים
 - סימטריה / זנב ימינה או שמאלה
 - ערכים קיצוניים המעידים על תצפיות מיוחדות או טעויות מדידה.
- היסטוגרמה נעה : שמים את רוחב כל תא על כל נקודה ממשית בציר ה- x ולאותה נקודה נותנים כערך את מספר התצפיות ברוחב שמדדנו. אם נקח רוחב תא קטן מדי, יהיו לנו הרבה קפיצות, ואם נקח רוחב תא גדול מדי, נאבד אינפורמציה. **טרנספורמציות של x** : שינוי סקאלה כדי שתצוגת הנתונים תהיה אינפורמטיבית, כגון טרנס' \log .

תמצית מספרית של נתונים מספריים :

הגדרות :

עבור אוסף תצפיות $x = (x_1, \dots, x_n)$, נגדיר :

תמצית אמפירית (summary statistic) : של אוסף נתונים x הוא פונקציה $\mathbb{R}^n \rightarrow \mathbb{R}$ שאינה תלויה בסדר הנתונים.

סטטיסטי הסדר (order statistic) : של אוסף נתונים x הוא אותו אוסף הערכים, אך מסודר בסדר עולה (וקטור ערכים ממויין).

שברונים ואחוזונים של התפלגות אמפירית (Percentiles, Quantiles) :

השברון ה- q כאשר $0 \leq q \leq 1$ עבור ההתפלגות האמפירית הוא : $X_q = X_{qn+0.5}$, והוא האחוזון ה- $100q$. למשל : $q = 0.5$ הוא השברון ה-0.5, שהוא האחוזון ה-50%, כלומר החציון במקרה זה. אם $qn + 0.5$ אינו שלם, נקח את הערך הנופל בין $[qn + 0.5]$ ל- $[qn + 0.5]$ באופן פרופורציונאלי למרחק ביניהם (אינטרפולציה לינארית) :

$$X_q = [[qn + 0.5] - (qn + 0.5)] \cdot X_{[qn+0.5]} + [(qn + 0.5) - [qn + 0.5]] \cdot X_{[qn+0.5]}$$

נשים לב כי כל מרחק מכפילים בשברון הנגדי לו, כיוון שהמרחק הקצר = השברון שקרוב אליו משפיע יותר על X_q .

הערה : $q < \frac{1}{2n}$ או $q > \frac{2n-1}{2n}$ אינו מוגדר.

קריטריונים לבחירת תמציות :

(1) נקודת השבירה :

אחוז התצפיות שצריך "לקלקל" בכדי לגרום לשינוי לא חסום בתמצית. דוגמאות :

- ממוצע : נקי' שבירה $\frac{1}{n}$ כי מספיק לשלוח תצפית אחת לאינסוף כדי לקלקל את הממוצע – שיהיה גם הוא אינסוף.
 - חציון : בערך $\frac{1}{2}$, למשל במדגם אי זוגי נוכל לקלקל את עד $\lfloor \frac{n}{2} \rfloor$ תצפיות, והחציון עדיין בטווח של האוסף המקורי (שהוא $X_{(1)}$ עד $X_{(n)}$).
- נקודת השבירה האסימפטוטית : גבול נקודת השבירה כאשר $n \rightarrow \infty$. למשל : עבור ממוצע : 0 ; חציון : $\frac{1}{2}$; ממוצע קצוץ α :

(2) אינווריאנטיות (אי תלות בסקאלה) :

אינוו' לטרנס' מונוטונית היא שמתקיים : $f(T(X)) = T(f(X))$, עבור $f: \mathbb{R} \rightarrow \mathbb{R}$ פונ' מונוטונית. למשל : ממוצע : לא ; חציון : כן ; קצוץ α : לא.

תמציות למיקום :

באופן אבסטרקטי – "אמצע" הנתונים שלנו (כמו ממוצע או חציון). פורמלית, פונקציה $T: \mathbb{R}^n \rightarrow \mathbb{R}$ המקיימת :

$$T(X + a) = T(X) + a$$

$$T(cX) = cT(X)$$

דוגמאות לתמציות למיקום (מקיימות את שתי התכונות):

- ממוצע: $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$
- ממוצע משוקלל: $\bar{X}_w = \sum_{i=1}^n w_i X_i$, כאשר: $\sum_{i=1}^n w_i = 1$.
- תציון: $X_{0.5}$ - הסדרון היחיד המקיים את התכונה השניה לכל c . כל שאר הסדרונים מקיימים רק עבור $c > 0$.
- ממוצע קצוץ: $T_\alpha(X) = \frac{1}{n-2\lfloor n\alpha \rfloor} \sum_{i=\lfloor n\alpha \rfloor+1}^{n-\lfloor n\alpha \rfloor} X_{(i)}$; α - עובר סטטיסטי הסדר, כלומר X ממויין).

תמציות לפיזור:

פונקציה $T: \mathbb{R}^n \rightarrow \mathbb{R}$ המקיימת:

- $T(X + a) = T(X)$
- $T(cX) = |c| \cdot T(X)$, $c \geq 0$, מכאן ש: $T(X) = T(-X)$
- $T(X) \geq 0$

דוגמאות לתמציות לפיזור:

- טווח: $X_{(n)} - X_{(1)}$, נקי שבירה $\frac{1}{n}$ אסימפי 0 (מספיק לשנות תצפית אחת ל- ∞).
- סטיית התקן האמפירית: $\sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$, נקי שבירה $\frac{1}{n}$ אסימפטוטית 0. השונות האמפירית לא מקיימת את התכונה השניה, כיוון שהכפלה ב- c גוררת הכפלה ב- c^2 .
- טווח בין רביעונים: $X_{0.75} - X_{0.25}$, נקי שבירה בערך $\frac{1}{4}$, אסימפי $\frac{1}{4}$.
- MAD (המדד המשוער): $MAD(X) = \text{median}\{|X_i - X_{0.5}|\}$, כלומר: חציון כל הערכים המוחלטים של הפרשים מהחציון. נקי שבירה $\frac{1}{2}$ אסימפי $\frac{1}{2}$. טענה: כל תמצית מהצורה: $T_1, T_2, T_1\{|X_i - T_2(X)|\}$ תמצית למיקום, היא תמצית לפיזור (לפי התכונות).

תמציות לנטייה:

נגדיר תחילה פוני נטייה Sk : $Sk(i) = \frac{X_{(i)} + X_{(n-i+1)}}{2} - X_{0.5}$ - לוקחים ממוצע שני סדרונים הנמצאים במרחק שווה מהאמצע, ומחסירים החציון. נטייה ימינה (זנב ימינה): Sk פוני יורדת של i .

פונקציה $T: \mathbb{R}^n \rightarrow \mathbb{R}$ המקיימת:

- $T(X + a) = T(X)$
- $c \geq 0, T(cX) = T(X)$
- $T(-X) = -T(X)$, ומצירוף תכונות 1 ו-2 נובע שאם המדגם סימטרי אז $T(x) = 0$ (אין נטייה).
- $Sk(i) > 0 \Leftrightarrow i$ יורד ב- i (נטייה ימינה) $\Leftrightarrow T(X) > 0$.

דוגמאות לתמציות לנטייה:

- מדד YULE לנטייה: $YULE(X) = \frac{(X_{0.75} + X_{0.25})/2 - X_{0.5}}{(X_{0.75} + X_{0.25})/2}$
- מדד Pearson: $Pear(X) = \frac{\sum_{i=1}^n (X_i - \bar{X})^3}{[\sum_{i=1}^n (X_i - \bar{X})^2]^2}$

מטרות ההצגה הגרפית:

1. זיהוי אשכולות (*clustering*) - קבוצות המתנהגות באופן דומה לפי מדדים שונים.
 2. זיהוי וחקר תצפיות חריגות.
 3. תיאור קשר בין משתנים.
 4. הבנת ההתפלגות המותנה: $P(Y|X)$.
- מטרה חשובה של ניתוח נתונים היא מציאת סיבתיות, אך גם בניית גרפי ומתמטי יתכן ונמצא קורילציה, אך לא בטוח שהיא סיבתית.

מידול מתמטי של קשרים בין משתנים – רגרסיה לינארית :

עבור משתנה מסביר X ומשתנה מוסבר (תלוי) Y , אנו רוצים לתאר במספר את הקשר הלינארי ביניהם (2 מספרים).

שיטת הקו החסיין (Resistant line):

נתון אוסף זוגות מספרים: $\{(x_1, y_1), \dots, (x_n, y_n)\}$.

- נחלק את ציר ה- x ל-3 חלקים שווים לפי $X_{\frac{1}{3}}, X_{\frac{2}{3}}$. נסמן את הקבוצות: low, mid, hi .
- ניקח חציוני y ל- low, hi : $(x_l, y_l), (x_h, y_h)$.
- נגדיר שיפוע: $b_{RL} = \frac{y_h - y_l}{x_h - x_l}$.
- אנו רוצים מחצית מהנקודות מעל הקו ומחצית מתחת, נסמן: $r_i = y_i - b_{RL}x_i$. נגדיר את החותך: $a_{RL} = \text{median}\{r_i\}$.
- עבור הקו החסיין שהתקבל $y = a_{RL} + b_{RL}x$ מתקיים ש- $y_i - (a_{RL} + b_{RL}x_i) \geq 0$ עבור בדיוק מחצית מהתצפיות, כנדרש.
- נקודת השבירה היא $\frac{1}{6}$ - קלקול עד חצי (בערך) מתוך $\frac{1}{3}$ מהנתונים.

קו הריבועים הפחותים (Least-squares line):

הרעיון של בניית הקו: מגדירים קו כללי כלשהו ע"י a, b (חיתוך, שיפוע), ולפיו מגדירים r_i - הסטיה של הנקודה (x_i, y_i) מהקו. נגדיר את RSS (Residual sum of squares) להיות סכום ריבועי הסטיות הללו. קו הריבועים הפחותים יהיה a, b שיביאו את RSS למינימום. נקבל את הקו

$$b_{LS} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\text{cov}_{amp}(x, y)}{\text{var}_{amp}(x)}, a_{LS} = \bar{y} - b_{LS}\bar{x}, y = a_{LS} + b_{LS}x$$

נקבל כי נקודת הממוצעים (\bar{x}, \bar{y}) תמיד נמצאת על קו זה.

מדידת טיב התאמת קו הריבועים הפחותים לנתונים :

מקדם המתאם של פירסון (r^2):

$$r_{xy} = \rho = \frac{\text{cov}_{amp}(x, y)}{\sqrt{\text{var}(x) \cdot \text{var}(y)}}. b_{LS} \text{ מתקיים: } b_{LS} = r_{xy} \cdot \frac{\text{sd}(y)}{\text{sd}(x)}$$

- $r_{xy} = r_{yx}$
- אם $b > 0$, f טרנסי לינארית, אזי: $r(x, f(y)) = r(f(x), y) = r(x, y)$, ומכאן שאין קשר לסקאלה של הצירים. אם $b < 0$ אז נקבל שזה שווה ל- $-r(x, y)$.
- $r(x, a + bx) = \begin{cases} 1, & b > 0 \\ -1, & b < 0 \\ 0, & b = 0 \end{cases}$. אם הקו עובר בכל הנקודות, נקבל $|1|$.
- $-1 \leq r_{xy} \leq 1$

משמעות r^2 :

r^2 הוא: אחוז השונות המוסברת, כלומר, איזה אחוז מהשונות שהתחלנו ממנה ($\text{var}(y)$) מוסבר ע"י קו הריבועים הפחותים. כלומר, אם נקח $b = 0$ (ואז \bar{y}) a נקבל שהשונות של y הוא RSS עבור ערכים אלו של a, b .
הסבר: אם ניקח שיפוע 0, ברור ש- $r^2 = 0$. כמו כן נקבל קו אופקי, שלא מסביר כלום מהשונות של y , כלומר לא "מפחית" מהשונות שהיתה קודם. לכן ה- RSS שנקבל הוא $\text{var}(y)$. כלומר, 0 אחוז מהשונות הוסבר ע"י הקו, ולכן סכום ריבועי המרחקים מהקו הוא השונות שהיתה ונשארה. בקיצור: פיזור גדול סביב הקו = אחוז מוסבר קטן = r^2 קטן.

תכונות וחולשות r^2 :

- זהו מדד לאיכות המודל הלינארי. רצוי להשוות לפי מדד זה רק בין מודלים שהותאמו על אותם נתונים.
- מדד זה רגיש לגודל הרעש - תכונה רצויה, אך גם רגיש לכמות הנתונים - תכונה לא רצויה (עם 2 נק' בלבד נקבל $r^2 = 1$ תמיד).

ניתוח שאריות וטרנסי' ללינאריות :

נסמן את השאריות $\delta_i = y_i - \hat{y}_i$, כאשר $\hat{y}_i = a_{LS} + b_{LS}x_i$.

אם ישנו סדר או מגמה בשאריות, אזי הקשר בין x ל- y כנראה לא לינארי. נניח f היא פונקציה לא לינארית המתארת את הקשר בין x ל- y , אזי עבור $z_i := f(x_i)$ נוכל להתאים קו ישר $\hat{y}_i = a_{LS} + b_{LS}z_i$ עם $a_{LS} = 0, b_{LS} = 1$, ונקבל התאמה מושלמת.

כללי אצבע בהסתכלות על שאריות :

• אם לשארית צורה קמורה עם בטן כלפי מטה, אז :

○ אם $b_{LS} > 0$ יש לנסות את הטרנסי' עבור x^p עבור $p > 1$ או y^q עבור $q < 1$.

○ אם $b_{LS} < 0$ יש לנסות את הטרנסי' עבור x^p עבור $p < -1$ או y^q עבור $q < 0$.

• אם לשארית צורה קעורה (בטן מעלה) : עבור x^p עבור $-1 < p < 1$, או y^q עבור $1 < q < -1$.

גרסייה רב משתנית (אותה גברת בשינוי לאדרת ממש מכוערת ומגעילה) :

כעת מתקיים כי $x_i \in \mathbb{R}^p$ עבור $p \geq 1$ טבעי כלשהו - p משתנים מסבירים ל- y . נכתוב וקטור עמודה $x_i = (x_{i1}, \dots, x_{ip})$ ונרצה להתאים את

המודל $\hat{y}_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}$ ($\beta = (\beta_0, \dots, \beta_p)$) הם הפרמטרים שנרצה להתאים.

קריטריון RSS : $RSS(\beta) = \sum_{i=1}^n (y_i - \hat{y}_i)^2$ (כמו קודם, רק עם ה- \hat{y} החדש). לפי כתיב מטרציוני נקבל שזו נורמה ריבועית אוקלידית של וקטור :

$RSS = \|y - x\beta\|^2$, כאשר כאן : $y = (y_1, \dots, y_n)^t$ וקטור שורה של כל ה- y_i ; $x \in Mat_{n \times (p+1)}$ - מטריצה שכל שורותיה הן x_i כמוגדר לעיל.

נרצה גם כאן למצוא β שיביא את RSS למינימום, ונקבל : $\hat{\beta} = (x^t x)^{-1} \cdot x^t \cdot y$.

משתנים מקריים רציפים :

פונקציית הסתברות מצטברת ופונקציית צפיפות :

תהי F פונקציית הסתברות מצטברת עם התכונות :

• $F(a) = 0, F(b) = 1$ עבור a, b כלשהם על ציר ה- x .

• F לא יורדת.

נאמר שמ"מ X מתפלג ע"פ $F : X \sim F$ אם לכל $x \in \Omega$ מתקיים : $P(X \leq x) = F(x)$.

פונקציית הצפיפות $f(x)$ תהיה : $f(x) = \frac{\partial F(x)}{\partial x}$. תכונות הצפיפות :

• $f(x) \geq 0$ לכל $x \in \Omega$

• $\int_a^b f(x) dx = 1$

דוגמאות :

• מ"מ אחיד רציף סטנדרטי : $X \sim U(0,1), \Omega = [0,1]$, מתקיים : $f_X(x) = \begin{cases} 0, & x < 0 \\ 1, & 0 \leq x \leq 1 \\ 0, & 1 < x \end{cases}$, $F_X(x) = \begin{cases} 0, & x < 0 \\ x, & 0 \leq x \leq 1 \\ 1, & 1 < x \end{cases}$

• מ"מ נורמלי סטנדרטי : $X \sim N(0,1), \Omega = \mathbb{R}$, $f_X(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$, $F_X(c) = \Phi(c) = \int_{-\infty}^c f_X(x) dx$

• מ"מ נורמלי כללי : $X \sim N(\mu, \sigma^2)$, $f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$, $F_X(c) = \Phi\left(\frac{c-\mu}{\sigma}\right)$

התפלגות משותפת מותנה של מספר מ"מ רציפים :

יהיו X, Y מ"מ רציפים. נגדיר :

• התפלגות משותפת : $F_{X,Y}(x, y) = P(X \leq x, Y \leq y)$

• התפלגות מותנה : $F_{Y|X}(y|x) = P(Y \leq y | X \leq x) = P(Y \leq y, X \leq x) / F_X(x)$

• צפיפות משותפת : $f_{X,Y}(x, y) = \partial^2 F_{X,Y}(x, y) / \partial x \partial y$

אם X, Y ביית אזי : $f_{X,Y}(x, y) = f_X(x)f_Y(y), F_{Y|X}(y|x) = F_Y(y), F_{X,Y}(x, y) = F_X(x)F_Y(y)$

תוחלת ושונות מ"מ רציפים :

יהי $X \sim F_X$ מ"מ רציף עם צפיפות f_X , אזי :

- תוחלת: $E(X) = \int_{\Omega} x f_X(x) dx$
 - שונות: $var(X) = \int_{\Omega} (X - EX)^2 f_X(x) dx$ (חלק חשוב בחישוב: $E(g(X)) = \int_{\Omega} g(x) f_X(x) dx$)
- דוגמאות:

- $E(X) = \frac{1}{2}, var(X) = \frac{1}{12} : X \sim U(0,1)$
- $E(X) = \frac{a+b}{2}, var(X) = \frac{(b-a)^2}{12} : X \sim U(a,b)$
- $E(X) = \mu, var(X) = \sigma^2 : X \sim N(\mu, \sigma^2)$ (מן הסתם). ברור: $X \sim N(0,1)$

אחוזונים ושביונים של התפלגויות רציפות :

נתונה פונקציית התפלגות מצטברת F_X . השברון q הוא: $F_X(X_q) = q$ s.t. X_q כלומר $X_q = F_X^{-1}(q)$. דוגמאות:

- $X_q = q : X \sim U(0,1)$
- $X_q = a + q(b-a) : X \sim U(a,b)$
- $Z_q := \Phi^{-1}(q) : X \sim N(0,1)$ כלומר $\Phi(Z_q) = q$, ערכים לפי טבלת ההתפלגות Z .
- $P(X \leq c) = \Phi\left(\frac{X-\mu}{\sigma}\right) \Rightarrow q = \Phi\left(\frac{X-\mu}{\sigma}\right) \Rightarrow X_q = \sigma Z_q + \mu : X \sim N(\mu, \sigma^2)$

משפט הגבול המרכזי לקירוב נורמלי :**משפט הגבול המרכזי (Central limit theorem):**

יהיו X_1, \dots, X_n מ"מ ממשיים (לאו דווקא רציפים), ב"ת ושוו התפלגות בעלי תוחלת μ ושונות σ^2 , אזי: $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \xrightarrow[n \rightarrow \infty]{p} N(0,1)$ כלומר:

- עבור n גדול מספיק ניתן להגיד כי $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$ או בקיצור: $\bar{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right)$. דוגמאות:
- $\sum_{i=1}^n X_i \sim Bin(n, p), X_i \sim Bernoulli(p)$ לפי משפט הגבול המרכזי נקבל את הקירובים:
- $\bar{X} \sim N\left(p, \frac{p(1-p)}{n}\right)$ ומכאן שגם $\frac{1}{n} Bin(n, p) \sim N\left(p, \frac{p(1-p)}{n}\right)$ (כי $\bar{X} = \frac{\sum X}{n}$).
- $\bar{X} \sim N\left(\frac{1}{2}, \frac{1}{12n}\right) : X_i \sim U(0,1)$

מתי הקירוב הנורמלי מתאים :

- הערך של μ לא משנה לאיכות הקירוב ואילו של σ^2 חשוב.
- עבור בינומי מקובל להשתמש אם $\mu = np \geq 10$ וגם תוחלת הכשלונות $n(1-p) \geq 10$.
- מקובל $n \geq 30$ חסם תחתון לכלל ההתפלגויות הרציפות, אך אין כללי אצבע ברורים.

הערות:

- חוק המספרים הגדולים: $(\bar{X}_n - \mu) \xrightarrow[n \rightarrow \infty]{p} 0$ (נובע מאי שוויון צ'בישב).
- ממוצע של מ"מ המתפלגים $N(\mu, \sigma^2)$ לא מתפלג בקירוב $N(\mu, \frac{\sigma^2}{n})$, אלא בדיוק כך.

מבוא להסקה סטטיסטית :**מושגי יסוד באמידה :**

- **אוכלוסיה :** אוסף סופי / אינסופי של פריטים בעלי תכונה / תכונות המעניינות אותנו.
- **התפלגות האוכלוסיה :** תיאור הסתברותי של הערך X של תכונה המעניינת אותנו בפרט מקרי באוכלוסייה. למשל:
 - $X \sim \text{קטגוריאלי בעל שני ערכים (כמו מגדר)} : X \sim \text{Bernoulli}(p)$, יהיה 1 בהסתברות p ו-0 בהסתברות $1-p$.
 - $X \sim N(\mu, \sigma^2)$: תיאור יכול להיות מדויק רק עבור אוכלוסייה אינסופית לא בת מניה. לרוב יהווה קירוב מספק. במקרה של אוכלוסיה סופית, ההתפלגות האמיתית של X היא פשוט ההתפלגות האמפירית של האוכלוסיה.
- **פרמטר :** תמצית של התכונה המעניינת אותנו באוכלוסיה, למשל תוחלת. נסמן פרמטר המעניין אותנו באות המתאימה, או באופן גנרי: θ .
- **מדגם מקרי (random sample) :** בגודל n הוא אוסף n פרטים הנדגמים בסיכוי שווה עם החזרה מהאוכלוסיה. המדגם הוא מ"מ מקרי n מימדי: $X = (X_1, \dots, X_n)$ וערכיו הם גם וקטור n מימדי: $x = (x_1, \dots, x_n)$.
- **סטטיסטי (statistic) :** תמצית מספרית של המדגם. נסמנו ב- $S(X)$, והוא גם מ"מ. את ערכו במדגם נסמן $S(x)$.
- **אומדן לפרמטר (estimator) :** סטטיסטי שמכוון להעריך את אורכו של הפרמטר באוכלוסיה. למשל: ממוצע המדגם המקרי כאומדן ל- μ .

תכונות אומדים ואיכותם :

- **הטיה (Bias) :** עד כמה ה"מיקום" של האומדן הוא נכון.

אומדן S חסר הטיה לפרמטר θ אם: $\forall \theta: E_\theta(S(X)) = \theta$, כלומר: תוחלת האומדן לפרמטר היא הפרמטר עצמו. אם האומדן אינו חסר הטיה, נגדיר את ההטיה שלו ($Bias$), שהיא: $B(\theta) = \theta - E_\theta(S(X))$. דוגמא: $\hat{p} = \frac{\sum X_i}{n}$, האם \hat{p} חסר הטיה: $E(\hat{p}) = \frac{\sum E(X_i)}{n} = \frac{np}{n} = p \Leftrightarrow$ אכן חסר הטיה. הערה: ניתן להשתמש גם במדדים אחרים למיקום לחישוב הטיה.
- **מדד פיזור :**

עד כמה ניתן "לסמוך" על הערך של $S(X)$ במדגם. נהוג להשתמש ב- $var_\theta(S(X))$ או ב- $\sigma_\theta(S(X))$. במקרה ברנולי: $var(\hat{p}) = \frac{p(1-p)}{n}$.

שילובים של הטיה ופיזור בקביעת איכות האומדן :

$$MSE_\theta(S(X)) = E_\theta(S(X) - \theta)^2$$

- אם נשתמש באומדן חסר הטיה נקבל כי $MSE_\theta(S(X)) = var(S(X))$.
- אם האומדן מוטה נקבל כי $MSE_\theta(S(X)) = var(S(X)) + B^2(\theta)$.

הערות:

- שימוש להשוואת אומדים: יהיו S, T אומדים; נאמר כי S שולט על T אם $\forall \theta: MSE_\theta(S(X)) \leq MSE_\theta(T(X))$. לדוגמא, עבור מקרה ברנולי נהוג לאמוד את p ב- \bar{X} , אך אומדן לפלס: $L(X) = \frac{\sum X_i + 1}{n+2}$ הוא אומדן לרוב מוטה אך עם MLE נמוך יותר (חסר הטיה ב- $\frac{1}{2}$).
 - רווחי סמך ברמת סמך (ביטחון) α : ערכים $\varepsilon_1, \varepsilon_2$ כך שברמת ביטחון $1 - \alpha$ מתקיים: $\theta \in [S(X) - \varepsilon_1, S(X) + \varepsilon_2]$.
- תכונה כללית של ממוצע המדגם \bar{X} למקרים נורמלי וברנולי:

$$E(\bar{X}) = E(X) \text{ - חסר הטיה.}$$

$$var(\bar{X}) = \frac{var(X)}{n}$$

$$\widehat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \text{ אומדן חסר הטיה לשונות במקרה הנורמלי.}$$

עקיבות :

יהי $T_n(X_n)$ אומדן מוצע ל- θ . עקיבות: $T_n(X_n) \xrightarrow[n \rightarrow \infty]{p} \theta$, כלומר: עם מספיק נתונים, האומדן שלנו יהיה נכון.

הגדרת התכנסות בהסתברות:

נאמר כי $T_n(X_n) \xrightarrow[n \rightarrow \infty]{p} \theta$ אם: $P(|T_n(X_n) - \theta| > \varepsilon) \xrightarrow[n \rightarrow \infty]{} 0, \forall \varepsilon$. למשל, \bar{X} כאומדן ל- μ הוא תמיד עקיב (בנוסף להיותו תמיד חסר הטיה). כמו

כן \hat{p} במקרה הבינומי. דוגמא פחות טריוויאלית: $T_n(X_n) = \max\{X_i\}$ הוא עומד עקיב במקרה האחד של $X_i \sim U(0, \theta)$.

- עקיבות אינה גוררת חוסר הטיה.
- כמו כן חוסר הטיה אינה גוררת עקיבות. למשל בהתפלגות נורמלית נקח את $T_n(X_n) = X_1$. $E(X_1) = \mu$ אך הוא לא עקיב.

גישות ליצירת אומדים :**פונקציית הנראות (Likelihood) :**

נניח $X_i \sim f_\theta$ (או P_θ במקרה הבדיד) ; נתייחס באופן כללי ל- f_θ פונקציית צפיפות / הסתברות, ו- $x = (x_1, \dots, x_n)$ מדגם מקרי. אזי:
 $L(\theta; x) = f_\theta(x_1) \cdot \dots \cdot f_\theta(x_n)$ - היא פונקציית הנראות. לרוב נשתמש בטרנס' \log של הנראות: $\ell(\theta; x) = \log(L(\theta; x))$. דוגמאות:

• ברנולי: $P_p(X) = \begin{cases} p, & X = 1 \\ 1-p, & X = 0 \end{cases}$ ולכן: $L_p = p^{\sum x_i} \cdot (1-p)^{n-\sum x_i}$, $\ell_p = \sum x_i \cdot \log(p) + (n - \sum x_i) \log(1-p)$

• נורמלי עם שונות ידועה: $L_\mu = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}}$, $\ell_\mu = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$

אומד נראות מקסימלי ($\hat{\theta}_{MLE}$) ותכונותיו :

הערך של θ שיביא למקסימום את (לוג) פונקציית הנראות: $\hat{\theta}_{MLE} = \underset{\theta \in \Theta}{\operatorname{argmax}} L(\theta)$ כדי למצוא אני"מ נגזור את $\ell(\theta; x)$ (או את $L(\theta; x)$ כפונקציה של θ , ונשווה לאפס למציאת קיצון, וע"י נגזרת שניה נוודא שהוא אכן מקסימום (נגזרת שניה קטנה מאפס). דוגמאות:

- בינומי: מתברר שאכן $\hat{p}_{MLE} = \frac{\sum x_i}{n}$ הוא \hat{p}_{MLE} .
- נורמלי (שונות ידועה): $\hat{\mu}_{MLE} = \frac{\sum x_i}{n} = \bar{X}$ גם כן.
- המקרה האחד: $L_\theta = \begin{cases} \left(\frac{1}{\theta}\right)^n, & 0 \leq x_1, \dots, x_n \leq \theta \\ 0, & o/w \end{cases}$ ולכן נרצה את הערך החוקי המינימלי של θ שיקיים $x_1, \dots, x_n \leq \theta$. זה יתקיים בודאות עבור $\max\{x_i\}$ ולכן $\hat{\theta}_{MLE} = \max\{x_i\}$

תכונות אני"מ :

- עקיבות: אם $X \sim F_\theta$ אז $\hat{\theta}_{MLE} \xrightarrow[n \rightarrow \infty]{} \theta$
- כל מיני תכונות אופטימליות אסימפטוטיות.
- אינוריאנטיות פונקציונלית: עבור פונקציה אחד לאחד מתקיים: $g(\hat{\theta}_{MLE}) = \widehat{g(\theta)}$ למשל נורמלי: $\widehat{\mu}_{MLE}^2 = \bar{X}^2$

רווחי סמך :**רווחי סמך ומשמעותם :**

נתון $X \sim F_\theta$, פרמטר θ ואומד $T(X)$. רווח סמך ברמת סמך $1 - \alpha$ מוגדר ע"י הערכים $\varepsilon_1, \varepsilon_2 > 0$ כך ש:
 $P_\theta(\theta \in [T(X) - \varepsilon_1, T(X) + \varepsilon_2]) \geq 1 - \alpha \Leftrightarrow P_\theta(T(X) \in [\theta - \varepsilon_2, \theta + \varepsilon_1]) \geq 1 - \alpha$
 בד"כ ילקח $\alpha = 0.05$, אז נאמר שיש לנו רמת סמך של 95% ($1 - \alpha$).

דוגמא: במקרה הנורמלי, \bar{X} אומד ל- μ , נדרוש $\varepsilon_1 = \varepsilon_2$ ונקבל: $C = \left[\bar{X} - Z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}, \bar{X} + Z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \right]$

משמעות רווח הסמך :

- האם $\mu \in C$ בודאות? **ודאי שלא בודאות.**
- האם $\mu \in C$ ברמת ביטחון של $1 - \alpha$? **ודאי שכן**, מהגדרה.
- האם זה אומר שלכל מדגם מקרי עתידי בגודל n נקבל סיכוי של $1 - \alpha$ ש- $\mu \in C$? **לא**, אך נוכל לבדוק האם הסיכוי גבוה מ- $1 - \alpha$ או נמוך ממנו: יהיו $X_1, X_2 \sim N(\mu, \sigma^2)$ אזי $\bar{X}_1, \bar{X}_2 \sim N(\mu, \frac{\sigma^2}{n})$ הם מ"מ ב"ת, מכאן ש: $\bar{X}_1 - \bar{X}_2 \sim N(0, \frac{2\sigma^2}{n})$. כעת נוכל לחשב: $P(\bar{X}_2 \in C)$

$$C = P\left(\frac{(\bar{X}_1 - \bar{X}_2)\sqrt{n}}{\sqrt{2}\sigma} \in \left[-\frac{Z_{1-\frac{\alpha}{2}}}{\sqrt{2}}, \frac{Z_{1-\frac{\alpha}{2}}}{\sqrt{2}}\right]\right) = 2\Phi\left(\frac{Z_{1-\frac{\alpha}{2}}}{\sqrt{2}}\right) - 1$$

רווח סמך לתוחלת נורמלית עם שונות לא ידועה :

נחליף את השימוש בסטיית התקן σ עם טעות התקן $\hat{\sigma}$, כאשר $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$. במקרה זה נשתמש ב**התפלגות t של סטודנט**, ונקבל:

$$t_{n-1} \sim \frac{(\bar{X} - \mu)}{\hat{\sigma}/\sqrt{n}} \sim t_{n-1} \text{ כלומר עם } n-1 \text{ דרגות חופש. בחישוב רווח סמך עם שונות לא ידועה נחליף את } Z_{1-\frac{\alpha}{2}} \text{ ב- } t_{n-1, 1-\frac{\alpha}{2}}. \text{ כאשר } n \rightarrow \infty \text{ אז } t_{n-1} \rightarrow Z$$

רווחי סמך לפרמטר בינומי :

$X_i \sim \text{Bernoulli}(p)$, רוצים למצוא רווח סמך ל- p כאשר נשתמש באומד \hat{p} . החישוב המדויק ארוך ומסורבל, לכן יש שתי גישות :

• קירוב נורמלי: $C = \left[\hat{p} - Z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}, \hat{p} + \dots \right] \Leftarrow$ משמעות: ברמת ביטחון של **בערך** (בגלל הקירוב ושימוש באומד לשונות) $1 - \alpha$

נצפה ש- p יפול בר"ס.

• שימוש באומד השמרני: פתרון לאי הדיוק הנובע משימוש באומד לשונות: נחליף את השימוש ב- \hat{p} תחת השורש במקסימום האפשרי שלו:

$\hat{p}(1 - \hat{p}) \leq 0.25$ נקבל ר"ס דומה, רק שנציב 0.25 במקום $\hat{p}(1 - \hat{p})$ משמעות: ברמת ביטחון של **לפחות** $1 - \alpha$...

אינווריאנטיות רווחי סמך תחת טרנס' מונוטונית :

אם C הוא ר"ס עבור θ ברמת ביטחון של $1 - \alpha$ ו- f היא פונ' מונוטונית, אזי $f(C)$ הוא ר"ס ברמת ביטחון $1 - \alpha$ עבור $f(\theta)$.

נקח את הדוגמא הבודקת את אחוז הסטודנטים באוכי שגובהם מתחת ל-170 ס"מ. בדרך הרגילה נשתמש בר"ס בינומי על סמך השיעור האמפירי במדגם, אך אז אנו מתעלמים מהנתון שהתפלגות האמיתית של גובהי הסטודנטים היא נורמלית, ולכן נקבל ר"ס גדול יותר מאשר טרנס' מונוטונית של ר"ס של גובהי הסטודנטים.

בדיקת השערות :

מושגי יסוד :

- **השערת האפס** (H_0): ברירת המחדל, העובדה שאנו רוצים להפריך באמצעות הנתונים, וזאת רק אם נסיק בצורה ברורה שאינה נכונה.
- **אלטרנטיבה** (H_A / H_1): ברור.
- **מבחן סטטיסטי ברמה** α : נניח $H_0: \theta = \theta_0$. מבחן סטטיסטי ברמה α יהיה אזור הדחיה C_α כך ש- $P_{H_0}(S(X) \in C_\alpha) \leq \alpha$. המבחן: אם $S(X) \in C_\alpha$, נדחה את השערת האפס, אחרת נקבלה. קיימים הרבה איזורי דחיה (המייצגים אלטרנטיבות), נבחר את האחד המייצג את האלטי' המעניינת אותנו. הערה: במקרה הרציף יהיה זה שוויון ממש.

כיצד נבחר בין אזורי דחיה אפשריים :

דוגמא במקרה הנורמלי: ונניח אנו דוחים עבור ערכים גבוהים, אז: $C_\alpha = [d_\alpha, \infty)$, נמצא את d_α :

$$P_{H_0}(\bar{X} \geq d_\alpha) = \alpha \Leftrightarrow P_{H_0}\left(\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \geq \frac{d_\alpha - \mu_0}{\sigma/\sqrt{n}}\right) = \alpha \Leftrightarrow \frac{d_\alpha - \mu_0}{\sigma/\sqrt{n}} = Z_{1-\alpha} \Leftrightarrow d_\alpha = \mu_0 + Z_{1-\alpha} \cdot \frac{\sigma}{\sqrt{n}}$$

כיוון שלא משתמשים כלל בערך של האלטי' $\theta_1 = \mu_1$, אזור דחיה זה יהיה נכון לכל $\mu_1 > \mu_0$ שנבחר כאלטי'. באופן דומה עבור אלטי' של ערכים נמוכים מ- μ_0 או אלטי' דו כיוונית – פשוט איחוד שני איזורי דחיה זרים, ושימוש ב- $Z_{1-\frac{\alpha}{2}}$. במקרה שונות לא ידועה: שימוש ב- $\hat{\sigma}^2$ והתפלגות t_{n-1} .

דוגמא למקרה הבינומי: $H_0: p = p_0, H_1: p > p_0$. במקרה זה נשתמש בקירוב הנורמלי, אך כלל ההחלטה (גדול שווה ל-10) ייבדק על p_0 (כאן מתבטאת העובדה שאנו בודקים את ההסתברות ליפול באזור הדחיה תחת השערת האפס). למקרה זה נקבל:

$$C_\alpha = [p_0 + Z_{1-\alpha} \sqrt{\frac{p_0(1-p_0)}{n}}, \infty)$$

סוגי השערות :

- **השערה פשוטה**: השערה הכוללת רק ערך אחד לפרמטר, למשל: $H_0: \theta = \theta_0$.
- **השערה מורכבת**: השערה הכוללת אוסף ערכים θ של θ , למשל: $H_1: \theta < \theta_0$. לא נעסוק בהשערות אפס מורכבות. אלטרנטיבה מהצורה $H_1: \theta > \theta_0$ היא חד צדדית, ואילו מהצורה $H_1: \theta \neq \theta_0$ היא דו-צדדית.

רמת מובהקות, סוגי טעויות ועוצמה :

רמת מובהקות של תוצאה (p -value):

נניח $H_0: \theta = \theta_0, H_1: \theta > \theta_0$, $S(X)$ אומד. בהיתן מדגם מקרי x ותוצאה $S(x)$, נרצה למצוא את הרמה המינימלית $\alpha^* = p$ -value כך ש- $S(x) \in C_{\alpha^*}$ כלומר: מה הסיכוי לקבל את התוצאה שקיבלנו או קיצונית ממנה.

במקרה הנורמלי, שונות ידועה: $\alpha^*(\bar{x}) = 1 - \Phi\left(\frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}\right)$, ונדחה את H_0 בכל רמה שגדולה או שווה ל- $\alpha^*(\bar{x})$. נשים לב כי נוסחה זו נובעת מכך ש-

$$\bar{x} = \mu_0 + Z_{1-\alpha^*} \cdot \frac{\sigma}{\sqrt{n}}$$

משמעות p -value:

ערכים נמוכים \Leftarrow אזור דחיה גדול יותר \Leftarrow הסיכוי לדחות את השערת האפס גדל. אם נשנה משהו בנתונים, למשל נגדיל את השונות, נקבל בהכרח p -value גדול יותר, שמשמעו – פחות סיכוי לדחות את השערת האפס. לא להתבלבל: דחיית השערת האפס היא עבור רמת ביטחון α כלשהי.

בדוגמת גבהי סטודנטים, $\sigma^2 = 16$, $\bar{x} = 175$, $H_1: \mu > 170$, $H_0: \mu = 170$, אם נשנה את $\sigma^2 = 144$ נקבל p -value גדול יותר. אינטואיטיבית: כשהשונות גדלה, פחות מפתיע אותנו לקבל \bar{x} במרחק 5 ס"מ מהתוחלת מאשר קודם, לכן פחות סביר לדחות את השערת האפס.

סוגי טעויות ועוצמת מבחן:

C_α . רמה α ואזור דחיה $S(X)$, $H_0: \theta = \theta_0, H_1: \theta = \theta_1$ סטטיסטי

- **טעות מסוג ראשון:** הסיכוי לדחות את H_0 כשהיא נכונה. זהו הסיכוי ש- $S(X) \in C_\alpha$ תחת P_{H_0} וזה שווה ל- α .
- **טעות מסוג שני:** הסיכוי שלא נדחה את H_0 כשהאלטרנטיבה נכונה: $P_{H_A}(S(X) \notin C_\alpha) = \beta$.
- **עוצמת מבחן:** הסיכוי שכן נדחה את H_0 כשהאלטרנטיבה נכונה: $\pi = 1 - \beta = P_{H_A}(S(X) \in C_\alpha)$.

בחירת אזורי דחיה והלמה של ניימן-פירסון:

הלמה של ניימן-פירסון (NP):

מבחן ברמה α בעל עוצמה מקסימלית:

להשערות פשוטות (θ_0, θ_A) הוא איזור דחיה C_α^* כך שלכל איזור דחיה אחר \tilde{C}_α ברמה α מתקיים: $\pi(C_\alpha^*) \geq \pi(\tilde{C}_\alpha)$. נגדיר יחס נראות:

$$\Lambda(x) := \frac{f_{\theta_0}(x)}{f_{\theta_A}(x)} = \frac{L(\theta_0; x)}{L(\theta_A; x)}$$

הלמה של ניימן-פירסון:

מבחן בעל עוצמה מקסימלית להשערות הפשוטות לעיל מוגדר ע"י: $C_\alpha^* = \{x | \Lambda(x) \leq d_\alpha^*\}$, כאשר d_α^* הוא הערך הקריטי של C_α^* , כלומר: $P(x \in C_\alpha^*) = \alpha$. תמיד נדחה לערכים נמוכים של יחס הנראות (בתרגול היחס הוגדר הפוך, כלומר θ_A במונה, לכן אמרנו שנדחה תמיד עבור ערכים גבוהים של $\Lambda(x)$).

במקרה הנורמלי: $H_0: \mu = \mu_0, H_A: \mu = \mu_A > \mu_0$, נקבל ש- $\Lambda(x)$ הוא פונקציה יורדת של \bar{x} . נקבל: $C_\alpha^* = \{x | \bar{x} \geq d_\alpha^*\}$. לכן נדחה את H_0 אמ"מ $\bar{x} \geq \mu_0 + Z_{1-\alpha} \cdot \frac{\sigma}{\sqrt{n}}$.
הוכחת הלמה: לא יכלל בסיכום.

מבחנים בעלי עוצמה מקסימלית לפי NP:

נורמלי עם שונות ידועה: כמתואר לעיל; עבור $H_A: \mu = \mu_A < \mu_0$: $C_\alpha^* = \{x | \bar{x} \leq \mu_0 - Z_{1-\alpha} \cdot \frac{\sigma}{\sqrt{n}}\}$.

נורמלי עם שונות לא ידועה: אותו דבר רק עם התפלגות t_{n-1} ו- σ^2 .

ברנולי/בינומי: $H_0: p = p_0, H_A: p = p_A > p_0$, נקבל כי מבחן NP הוא מהצורה: $C_\alpha^* = \{x | \hat{p} \geq d_\alpha^*\}$ (גם כאן $\hat{p} = \frac{\sum X_i}{n}$ הוא הסטטיסטי למבחן יחס נראות מקסימלי).

נשתמש בקירוב הנורמלי כדי לקבל מבחן עוצמה מקסימלית ברמה בקירוב α : $C_\alpha^* = \{x | \hat{p} \geq p_0 + Z_{1-\alpha} \cdot \sqrt{\frac{p_0(1-p_0)}{n}}\}$.

פואסון: $H_0: \lambda = \lambda_0, H_A: \lambda = \lambda_A > \lambda_0$, נקבל כי מבחן NP יהיה x עצמו: $C_\alpha^* = \{x | x \geq d_\alpha^*\}$.

הכללת NP – מבחנים בעלי עוצמה מקסימלית במידה שווה (UMP):

עבור $H_0: \theta = \theta_0$ ואלטרנטיבה מורכבת: $H_A: \theta \in \Theta$, נאמר כי אזור דחיה C_α^* מגדיר מבחן ברמה α בעל עוצמה מקסימלית במידה שווה אם:

• $P_{H_0}(x \in C_\alpha^*) = \alpha$

• $\forall \theta_A \in \Theta: H_A: \theta = \theta_A$ מגדיר מבחן עוצמה מקסימלית לכל אלטרנטיבה פשוטה

במקרה הנורמלי, שונות ידועה: אזור הדחיה שקיבלנו לא היה תלוי כלל ב- μ_A , כלומר התקיים לכל $\mu_A \in \{\mu_A | \mu_A > \mu_0\}$, ולכן נותן UMP.

כנ"ל שאר הדוגמאות (נורמלי עם שונות לא ידועה, בינומי/ברנולי, פואסון) נותנות UMP.

במקרה הדו-צדדי: אלטי מורכבת דו צדדית אינה UMP מכיוון שמבחן NP תלוי בכיוון האלטי.

הסקה סטטיסטית בבעיות רגרסיה:

ריבועים פחותים: נתונות תצפיות $(x_1, y_1), \dots, (x_n, y_n)$, מעריכים מודל: $\hat{y} = a + bx$, מגדירים פונקצית f (RSS) שהיא סכום ריבועי הפרשים: $f(a, b) = \sum_{i=1}^n (y_i - a - bx_i)^2$, ורוצים את הערכים של a, b שיביאו את f למינימום. נסתכל על a, b כפרמטרים שרוצים למדוד, והאומדים שלהם הם $\hat{a}_{LS}, \hat{b}_{LS}$. נעשה הסקה סטטיסטית על התפלגות מותנה:

נניח $Y|X = y \sim N(a + bx, \sigma^2)$, כאשר σ^2 לא ידוע. נתאר זאת כך: $Y|X = a + bx + \varepsilon$, כאשר $\varepsilon \sim N(0, \sigma^2)$ (הרעש).

נאמוד את a, b לפי נראות מקסימלית, ונקבל: $\ell(a, b; (x_1, y_1), \dots, (x_n, y_n), \sigma^2) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} f(a, b)$. במקרה זה חישובנו יחס נראות לפי H_A במונה, ולכן אנו רוצים ערכים גבוהים של היחס – כיוון ש- $f(a, b)$ עם סימן שלילי, זה שקול לערכים נמוכים של $f(a, b)$ – כמו שקיבלנו בעבר. מכאן ש: $\hat{a}, \hat{b} = \underset{a, b}{\operatorname{argmin}} f(a, b)$. וכפי שקיבלנו בעבר:

$$\hat{b} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}, \hat{a} = \bar{Y} - \hat{b}\bar{X}$$

מודל: $\varepsilon_i \sim N(0, \sigma^2), y_i = a + bx_i + \varepsilon_i$. ההשערות שנבדוק: $H_0: b = 0$ (כלומר הקו הוא קבוע ללא שיפוע, ונזכר שזה אומר ש- r^2 , אחוז השונות המוסבר, הוא 0), והאלטרנטיבה: $H_A: b \neq 0$.

כיוון שע"פ המודל $\forall i: E(\varepsilon_i) = 0$, מקבלים כי $E(\hat{b}) = b$, כלומר \hat{b} הוא אומדן חסר הטוה ל- b . לבסוף נקבל: $\hat{b} \sim N\left(b, \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}\right)$.

מכאן ש: $H_0: \hat{b} \sim N\left(0, \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}\right)$, ואומדן חסר הטוה ל- σ^2 : $\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - \bar{y})^2$. כיוון שיש לנו 2 פרמטרים שאומדים במקרה זה, ולכן

$$C_\alpha^* = \left(-\infty, -t_{n-2, 1-\frac{\alpha}{2}} \cdot \frac{\hat{\sigma} / \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}}{\sqrt{n}}\right] \cup \left[t_{n-2, 1-\frac{\alpha}{2}} \cdot \frac{\hat{\sigma} / \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}}{\sqrt{n}}, \infty\right)$$

מבחנים לקשר בין 2 התפלגויות / מ"מ

נניח $X \sim F, Y \sim G, \theta$ ל- F פרמטריים), θ ל- G פרמטריים), ψ בד"כ $\theta = \psi$. לדוגמה במקרה הנורמלי:

$X \sim N(\mu_X, \sigma_X^2), Y \sim N(\mu_Y, \sigma_Y^2)$, ניקח אומדים לתוחלת, $H_0: \mu_X = \mu_Y, H_A: \mu_X > \mu_Y$ (יכולה להיות כל אלטי אחרת). נתונים מדגמים $x = (x_1, \dots, x_n), y = (y_1, \dots, y_m)$.

- אם X, Y בלתי תלויים, נערוך מבחן לא מזווג של שני המדגמים.
- אם ישנה תלות, נערוך מבחן מזווג, כאשר המקרה המעניין הוא $x_i, y_i, n = m$ הן תצפיות על אותו אובייקט (כלומר ישנה תלות אך ורק בין x_i ל- y_i , וכל שאר היחסים הם בלתי תלויים).

מבחנים לא מזווגים לשני מדגמים

$\bar{X} \sim N\left(\mu_X, \frac{\sigma_X^2}{n}\right), \bar{Y} \sim N\left(\mu_Y, \frac{\sigma_Y^2}{m}\right)$, נקח את ההפרש ביניהם שגם הוא מ"מ: $\bar{Z} = \bar{X} - \bar{Y} \sim N\left(\mu_X - \mu_Y, \frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{m}\right)$.

נקבל כי $H_0: E(Z) = 0, H_A: E(Z) > 0$. והאלטרנטיבה היא $H_A: E(Z) > 0$. קיים מבחן UMP כמו במקרה הנורמלי הרגיל.

$$C_\alpha^* = \{x, y \mid \bar{x} - \bar{y} \geq Z_{1-\alpha} \cdot \sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{m}}\}$$

(ב) שונות לא ידועות:

- השונות לא ידועות אך ידוע שהן שוות, נסמן $\sigma_X^2 = \sigma_Y^2 = \sigma^2$. נעריך את σ^2 משני המדגמים יחד (בגלל שוויון

$$\widehat{\sigma}_{XY}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2 + \sum_{j=1}^m (Y_j - \bar{Y})^2}{n+m-2} = \frac{(n-1)\widehat{\sigma}_X^2 + (m-1)\widehat{\sigma}_Y^2}{n+m-2}$$

השונות לקבלת אומדן: $\widehat{\sigma}_{XY}^2$ ונערוך מבחן t עם $n+m-2$ ד"ח:

$$C_\alpha^* = \{x, y \mid \bar{x} - \bar{y} \geq t_{n+m-2, 1-\alpha} \cdot \sqrt{\frac{n+m}{nm} \widehat{\sigma}_{XY}^2}\}$$

- לא מניחים שוויון שונות: $\widehat{\sigma}_{\bar{X}-\bar{Y}}^2 = \frac{\widehat{\sigma}_X^2}{n} + \frac{\widehat{\sigma}_Y^2}{m}$. דרגות החופש יחושבו לפי תיקון Welch-Satterthwaite: $v = \frac{(\widehat{\sigma}_{\bar{X}-\bar{Y}}^2)^2}{\frac{\widehat{\sigma}_X^4}{n^2(n-1)} + \frac{\widehat{\sigma}_Y^4}{m^2(m-1)}}$, ונקבל:

$$C_\alpha^* = \{x, y \mid \bar{x} - \bar{y} \geq t_{v, 1-\alpha} \cdot \sqrt{\widehat{\sigma}_{\bar{X}-\bar{Y}}^2}\}$$

הסקה במדגמים מזווגים

$(x_i, y_i), n = m$ אינם בלתי תלויים (ישנה אי תלות בין כל שאר הזיווגים). נסמן $Z_i = X_i - Y_i$, ונקבל כי $Z \sim N(\mu_Z, \sigma_Z^2)$. נקבל את אותו ניסוח

השערות כמו קודם: $H_0: \mu_Z = 0, H_A: \mu_Z > 0$. נשים לב שמהתלות מתקיים: $\sigma_{X-Y}^2 \neq \sigma_X^2 - \sigma_Y^2$. $\sigma_{X-Y}^2 = \sigma_X^2 + \sigma_Y^2 - 2 \operatorname{cov}(X, Y) \neq 0$.

$$C_\alpha^* = \{x, y \mid \bar{z} \geq Z_{1-\alpha} \cdot \sqrt{\frac{\widehat{\sigma}_{X-Y}^2}{n}}\}$$

$$C_\alpha = \{x, y \mid \bar{z} \geq t_{n-1, 1-\alpha} \cdot \sqrt{\frac{\widehat{\sigma}_{X-Y}^2}{n}}\}$$

(ב) שונות לא ידועה: $\widehat{\sigma}_{X-Y}^2 = \widehat{\sigma}_Z^2 = \frac{\sum_{i=1}^n (Z_i - \bar{Z})^2}{n-1}$, ומכאן: $C_\alpha = \{x, y \mid \bar{z} \geq t_{n-1, 1-\alpha} \cdot \sqrt{\frac{\widehat{\sigma}_{X-Y}^2}{n}}\}$.

נסכם את המקרים השונים:

לא מזווגים	מזווגים	
נכון	נכון: עדיין מקבלים מבחן ברמה α אך מפסידים עוצמה (פחות דרגות חופש בזיווג)	X_i, Y_i ב"ת
לא נכון: רמת המבחן אינה α , עוצמת המבחן קטנה כיוון ש: $var(X - Y) < var(X) + var(Y)$ (כי $cov(X, Y) > 0$).	נכון	X_i, Y_i תלויים

הסקה על קשרים בין התפלגויות בדידות קטגוריאליות:

המקרה הבינומי (לא מזווג): כל ה- $n + m$ בלתי תלויים

$H_A: p_X > p_Y$ (בה"כ), n תצפיות X , m תצפיות Y . לפי הקירוב הנורמלי:

$$\widehat{p}_X - \widehat{p}_Y \sim N\left(p_X - p_Y, \frac{p_X(1-p_X)}{n} + \frac{p_Y(1-p_Y)}{m}\right) \Rightarrow H_0: p_X = p_Y =: p, \quad \widehat{p}_X - \widehat{p}_Y \sim N\left(0, \frac{p(1-p)}{n} + \frac{p(1-p)}{m}\right)$$

במקרה זה השונות תחת H_0 אינה ידועה, ולכן נאמוד אותה:

- **אומד הרפתקני:** $\hat{p} = \frac{n\widehat{p}_X + m\widehat{p}_Y}{n+m}$ ולכן $\sigma_{\widehat{p}_X - \widehat{p}_Y}^2 = \frac{n+m}{nm} \hat{p}(1-\hat{p})$
- **אומד שמרני:** $\hat{p} = 0.5$ ולכן $\sigma_{\widehat{p}_X - \widehat{p}_Y}^2 = \frac{n+m}{nm} \cdot \frac{1}{4}$

מכאן שאזור הדחיה יהיה: $C_\alpha = \{x, y \mid \widehat{p}_X - \widehat{p}_Y \geq Z_{1-\alpha} \cdot \sqrt{\sigma_{\widehat{p}_X - \widehat{p}_Y}^2}\}$

במידה ומספר ההצלחות הכולל ידוע מראש:

נסמן את מספר ההצלחות הכולל לשני המ"מ יחד כ- $n_+ + m_+$. נקבל כי תחת $H_0: n_+ \sim HG(n + m, n_+ + m_+, n)$ - גודל המדגם הוא $n + m$, מספר ההצלחות ("ה"אכולוסיה המיוחדת") הוא $n_+ + m_+$, ואנו לוקחים מדגם של n (המדגם X לצורך העניין, כי ההצלחות שלו מעניינות אותנו). במקרה זה נוכל להסיק לגבי נכונות השערת האפס בשלושה דרכים:

- הסקה מדוייקת בעזרת HG (מבחן Fisher exact test).
- קירוב נורמלי: $n \cdot \widehat{p}_X = n_+ \sim N\left(\frac{n(n_+ + m_+)}{n+m}, \frac{n(n_+ + m_+)(n+m-n_+ + m_+)(n+m-n)}{(n+m)^2(n+m-1)}\right)$
- מבחן χ^2 לטבלאות.

התפלגות חי בריבוע (χ^2):

הגדרה:

יהיו X_1, \dots, X_k מ"מ בלתי תלויים מהתפלגות נורמלית סטנדרטית, $X_i \sim N(0,1)$, אזי: $\sum_{i=1}^k X_i^2 \sim \chi_k^2$, כאשר k הוא מס' דרגות החופש. אם $X \sim \chi_k^2, Y \sim \chi_l^2$, אזי: $X + Y \sim \chi_{k+l}^2$.

נתון מדגם בגודל N עם שני ערכים של משתנים בדידים: U עם k ערכים אפשריים, Z עם l ערכים אפשריים. נרצה לבדוק אי תלות: בלתי תלויים - $H_0: U, Z$. נסכם את הנתונים בטבלת $observed$ בגודל $k \times l$:

נתנה על הערכים השוליים $m_1, \dots, m_l, n_1, \dots, n_k$ ע"י בניית טבלה שניה, טבלת ה- $expected$, מגודל זהה שערכיה יהיו $e_{ij} = \frac{n_i m_j}{N} = \frac{n_i}{N} \cdot \frac{m_j}{N} \cdot N$.

טענה:

אם כל התאים בטבלת ה- $expected$ (ה- $observed$?) מכילים לפחות 5 תצפיות אזי תחת H_0 (אלטרנטיבה דו-צדדית):

$$\sum_{i=1}^{k \times l} \frac{(o_i - e_i)^2}{e_i} \sim \chi_{(k-1)(l-1)}^2$$

	$Z = z_1$	$Z = z_2$...	$Z = z_l$	סה"כ
$U = u_1$	n_{11}	n_{12}		n_{1l}	n_1
$U = u_2$	n_{21}	n_{22}		n_{2l}	n_2
...
$U = u_k$	n_{k1}	n_{k2}	...	n_{kl}	n_k
סה"כ	m_1	m_2		m_l	N

רגרסיה מול χ^2 :

גישה אחרת לבדיקת תלות בין X, Y תהיה לעשות דיסקרטיזציה של הנתונים, למשל ל- $\{נמוך, בינוני, גבוה\}$, לעשות טבלה מתאימה (3 שורות ו-3 עמודות), ולערוך מבחן χ^2 לאי-תלות עם $(3-1)(3-1) = 4$ דרגות חופש. הרווח: בודקים אי תלות כלשהי, לאו דווקא לינארית; ההפסד: הסדר בין הקטגוריות. לכן גם מרוויחים עוצמה וגם מפסידים עוצמה למבחן.

מבחן χ^2 של פירסון לאיכות התאמה :

יהי X מ"מ בדיד המקבל ערכים מ- $\{a_1, \dots, a_k\}$, תהי $F = mult(p_1, \dots, p_k)$ התפלגות מולטינומית נתונה על a_i , ו- $H_0: X \sim F$. יהי x מדגם מקרי בגודל n בו רואים: n_1 תצפיות מסוג a_1, \dots, a_k , כאשר $\sum n_i = n$. ניתן להסתכל על זה בתור טבלה עם שורה אחת:

אם כל תא בטבלת ה- exp יכול 5 תצפיות ומעלה, אזי תחת H_0 :

$$\sum_{i=1}^n \frac{(n_i - np_i)^2}{np_i} \sim \chi_{k-1}^2$$

: *observed*

a_1	a_2	...	a_k	סה"כ
n_i				n

: *expected*

a_1	a_2	...	a_k	סה"כ
np_i				n

הערה: כיוון שאין סכומי עמודות להתנות עליהם, לא נכפיל את דרגות החופש ב- $(1 - 1) = 0$.

נושאים נוספים :

השוואות מרובות : לא נכלל בסיכום.

מבחנים סטטיסטיים לא פרמטריים : לא נכלל בסיכום.

אמידה בייסיאנית :

לפי הגישה הבייסיאנית, הפרמטר θ אותו אומדים הוא לא מספר אלא מ"מ. נסמן ב- $p(\theta)$ את ההתפלגות המקדימה (אפריורית) של θ - ה"אמונה" שלנו לגבי הפרמטר לפני שראינו את הנתונים. עם קבלת הנתונים נעדכן את ההתפלגות להתפלגות האפוסטריורית. עדכון ההתפלגות בהינתן x :

$$Pr(\theta | x) = \frac{p(x, \theta)}{p(x)} = \frac{f(x|\theta) \cdot p(\theta)}{p(x)} \propto f(x|\theta) \cdot p(\theta)$$

אם יש לנו ידע טוב על θ , $p(\theta)$ יהיה רווחי בגישה זו. כמו כן ניתן להסיק על θ ישירות. מצד שני, לא תמיד יהיה לנו ידע על θ והחישובים מסובכים. **דוגמא למקרה הנורמלי, שונות ידועה :**

$\mu | x \sim (\mu, \sigma^2)$, x מדגם בגודל n , ומעריכים את μ . לפי אמידה בייסיאנית: נניח $\mu \sim N(0, \sigma_\mu^2)$ (נצפה שהתוחלת תהיה קרובה ל-0), נחשב ונקבל:

$$\mu | x \sim N\left(\frac{\sigma_\mu^2}{\sigma_x^2 + \sigma_\mu^2} \cdot x, \frac{\sigma_\mu^2 \cdot \sigma_x^2}{\sigma_x^2 + \sigma_\mu^2}\right)$$