


תרגול 3 - מבחני טיב התאמה





אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מוטיבציה

בסימולציה, הרבה פעמים אנחנו לא יודעים מראש מה ההתפלגות של
רכיבים במערכת.



בסימולציה, הרבה פעמים אנחנו לא יודעים מראש מה ההתפלגות של
רכיבים במערכת.

לדוגמה:

זמני הגעה של לקוחות

זמני שירות

זמני תיקון

מספר אירועים ביחידת זמן



בסימולציה, הרבה פעמים אנחנו לא יודעים מראש מה ההתפלגות של רכיבים במערכת.

לדוגמה:

זמני הגעה של לקוחות

זמני שירות

זמני תיקון

מספר אירועים ביחידת זמן

נרצה לקחת נתונים אמיתיים מהמערכת, להתאים להם התפלגות הסתברותית, ואז להשתמש בהתפלגות הזאת במודל הסימולציה.





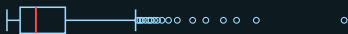


אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

רושם ראשוני - מציאת משפחה

לפני מבחן סטטיסטי, כדאי להסתכל על הנתונים.



לפני מבחן סטטיסטי, כדאי להסתכל על הנתונים.



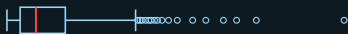

Value




Value



לפני מבחן סטטיסטי, כדאי להסתכל על הנתונים.



Value




Value

ויזואליזציה לא מוכיחה התאמה, אבל היא עוזרת לבחור משפחות מועמדות.



$$x_{(i)} \text{ vs. } q_i = F^{-1}\left(\frac{i - \frac{1}{2}}{n}\right), \quad i = 1, \dots, n$$

אם $x_{(i)} \approx q_i$ לכל i , הנקודות יהיו קרובות לקו ישר.





אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מציאת פרמטרים באמצעות MLE

נניח שבחרנו משפחה מועמדת, למשל
התפלגות מעריכית.


עכשיו צריך לאמוד את הפרמטרים שלה.



מציאת פרמטרים באמצעות MLE

נניח שבחרנו משפחה מועמדת, למשל
התפלגות מעריכית.

עכשיו צריך לאמוד את הפרמטרים שלה.







מציאת פרמטרים באמצעות MLE

נניח שבחרנו משפחה מועמדת, למשל התפלגות מעריכית.

עכשיו צריך לאמוד את הפרמטרים שלה.

פונקציית נראות (Likelihood)

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta)$$






מציאת פרמטרים באמצעות MLE

נניח שבחרנו משפחה מועמדת, למשל התפלגות מעריכית.

עכשיו צריך לאמוד את הפרמטרים שלה.



פונקציית נראות (Likelihood)

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta)$$

נבחר את θ שממקסם את הנראות:


$$\hat{\theta} = \arg \max_{\theta} L(\theta)$$

כדי להמנע ממודלים מסובכים מידי נשאף למזער את AIC ואת BIC:

$$AIC = -2 \log L + 2p$$


$$BIC = -2 \log L + p \log n$$

כשמספר הפרמטרים של המודל שלנו הוא p .





מציאת פרמטרים באמצעות MLE



נניח שבחרנו משפחה מועמדת, למשל התפלגות מעריכית.

עכשיו צריך לאמוד את הפרמטרים שלה.

פונקציית נראות (Likelihood)

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta)$$

נבחר את θ שממקסם את הנראות:


$$\hat{\theta} = \arg \max_{\theta} L(\theta)$$

כדי להמנע ממודלים מסובכים מידי נשאף למזער את AIC ואת BIC:

$$AIC = -2 \log L + 2p$$



$$BIC = -2 \log L + p \log n$$

כשמספר הפרמטרים של המודל שלנו הוא p .





מציאת פרמטרים באמצעות MLE



נניח שבחרנו משפחה מועמדת, למשל התפלגות מעריכית.

עכשיו צריך לאמוד את הפרמטרים שלה.

פונקציית נראות (Likelihood)

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta)$$

נבחר את θ שממקסם את הנראות:

$$\hat{\theta} = \arg \max_{\theta} L(\theta)$$

כדי להמנע ממודלים מסובכים מידי נשאף למזער את AIC ואת BIC:

$$AIC = -2 \log L + 2p$$


$$BIC = -2 \log L + p \log n$$

כשמספר הפרמטרים של המודל שלנו הוא p .



טבלת χ^2 - מה הערך בטבלה אומר?

$$X \sim \chi^2(df) \quad p = \Pr(X \geq \chi_{\text{crit}}^2) \quad \alpha = \int_{\chi^2}^{\infty} \frac{1}{2^{\nu/2}\Gamma(\nu/2)} x^{(\nu/2)-1} e^{-x/2} dx$$



$$\chi_{\text{stat}}^2 > \chi_{\text{crit}}^2 \implies H_0 \text{ דוחים את}$$



אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מבחני טיב התאמה

אחרי שמצאנו התאמה אפשרית, נרצה לבדוק אותה סטטיסטית.



אחרי שמצאנו התאמה אפשרית, נרצה לבדוק אותה סטטיסטית.

המידע שיש בידינו:

- הנתונים X
- התפלגות מוצעת F
- פרמטרים של ההתפלגות θ



אחרי שמצאנו התאמה אפשרית, נרצה לבדוק אותה סטטיסטית.

המידע שיש בידינו:

- X הנתונים
- התפלגות מוצעת F
- פרמטרים של ההתפלגות θ

ננסח השערות:

$$H_0 : X \sim F(\theta)$$

$$H_1 : X \not\sim F(\theta)$$



אחרי שמצאנו התאמה אפשרית, נרצה לבדוק אותה סטטיסטית.

המידע שיש בידינו:

- הנתונים X
- התפלגות מוצעת F
- פרמטרים של ההתפלגות θ

ננסח השערות:

$$H_0 : X \sim F(\theta)$$

$$H_1 : X \not\sim F(\theta)$$

אם לא דחינו את H_0 , זה לא אומר שהוכחנו שההתפלגות נכונה. זה אומר שאין לנו מספיק עדות לדחות אותה.



קובייה נזרקה 1800 פעמים. התוצאות:

Face	1	2	3	4	5	6
Observed	250	300	400	200	320	330



קובייה נזרקה 1800 פעמים. התוצאות:

Face	1	2	3	4	5	6
Observed	250	300	400	200	320	330

נרצה לבדוק האם הקובייה הוגנת.



קובייה נזרקה 1800 פעמים. התוצאות:

Face	1	2	3	4	5	6
Observed	250	300	400	200	320	330

נרצה לבדוק האם הקובייה הוגנת.

אם הקובייה הוגנת:

$$p_j = \frac{1}{6}$$

ולכן הצפי לכל תוצאה הוא:

$$1800 \cdot \frac{1}{6} = 300$$



נערוך מבחן סטטיסטי ברמת ביטחון 0.9, כלומר $\alpha = 0.1$.

$$\chi_{\text{stat}}^2 = \sum_{j=1}^k \frac{(n \cdot p_j - N_j)^2}{n \cdot p_j}$$



נערוך מבחן סטטיסטי ברמת ביטחון 0.9, כלומר $\alpha = 0.1$.

$$\chi_{\text{stat}}^2 = \sum_{j=1}^k \frac{(n \cdot p_j - N_j)^2}{n \cdot p_j}$$

בדוגמת הקובייה: $n \cdot p_j = 300$, $p_j = \frac{1}{6}$, $k = 6$,



נערוך מבחן סטטיסטי ברמת ביטחון 0.9, כלומר $\alpha = 0.1$.

$$\chi_{\text{stat}}^2 = \sum_{j=1}^k \frac{(n \cdot p_j - N_j)^2}{n \cdot p_j}$$

בדוגמת הקובייה: $n \cdot p_j = 300$, $p_j = \frac{1}{6}$, $k = 6$,

$$\chi_{\text{stat}}^2 = \frac{50^2}{300} + \frac{0^2}{300} + \frac{100^2}{300} + \frac{(-100)^2}{300} + \frac{20^2}{300} + \frac{30^2}{300} = 79.33$$



נערוך מבחן סטטיסטי ברמת ביטחון 0.9, כלומר $\alpha = 0.1$.

$$\chi_{\text{stat}}^2 = \sum_{j=1}^k \frac{(n \cdot p_j - N_j)^2}{n \cdot p_j}$$

בדוגמת הקובייה: $n \cdot p_j = 300$, $p_j = \frac{1}{6}$, $k = 6$,

$$\chi_{\text{stat}}^2 = \frac{50^2}{300} + \frac{0^2}{300} + \frac{100^2}{300} + \frac{(-100)^2}{300} + \frac{20^2}{300} + \frac{30^2}{300} = 79.33$$

דרגות החופש:

$$df = k - p - 1$$

כאשר p הוא מספר הפרמטרים של ההתפלגות המוצעת. במקרה של התפלגות אחידה אין פרמטרים נוספים ולכן $p = 0$ ובהתאם

$$\chi_{\text{crit}}^2 = \chi_{5,0.9}^2 = 9.24$$

משום ש $\chi_{\text{stat}}^2 > \chi_{\text{crit}}^2$ נדחה את ההשערה שהקובייה הוגנת.



df	.005	.01	.025	.05	.10	.25	.50	.75	.90	.95	.975	.99	.995
1	0.00004	0.00016	0.00098	0.0039	0.0158	0.102	0.455	1.32	2.71	3.84	5.02	6.63	7.88
2	0.0100	0.0201	0.0506	0.103	0.211	0.575	1.39	2.77	4.61	5.99	7.38	9.21	10.6
3	0.0717	0.115	0.216	0.352	0.584	1.21	2.37	4.11	6.25	7.81	9.35	11.3	12.8
4	0.207	0.297	0.484	0.711	1.06	1.92	3.36	5.39	7.78	9.49	11.1	13.3	14.9
5	0.412	0.554	0.831	1.15	1.61	2.67	4.35	6.63	9.24	11.1	12.8	15.1	16.7
6	0.676	0.872	1.24	1.64	2.20	3.45	5.35	7.84	10.6	12.6	14.4	16.8	18.5
7	0.989	1.24	1.69	2.17	2.83	4.25	6.35	9.04	12.0	14.1	16.0	18.5	20.3
8	1.34	1.65	2.18	2.73	3.49	5.07	7.34	10.2	13.4	15.5	17.5	20.1	22.0
9	1.73	2.09	2.70	3.33	4.17	5.90	8.34	11.4	14.7	16.9	19.0	21.7	23.6
10	2.16	2.56	3.25	3.94	4.87	6.74	9.34	12.5	16.0	18.3	20.5	23.2	25.2
11	2.60	3.05	3.82	4.57	5.58	7.58	10.3	13.7	17.3	19.7	21.9	24.7	26.8
12	3.07	3.57	4.40	5.23	6.30	8.44	11.3	14.8	18.5	21.0	23.3	26.2	28.3

$$\chi_{\text{stat}}^2 > \chi_{df, 1-\alpha}^2 \implies H_0 \text{ דוחים את}$$

בדוגמה: $df = 5$, $\alpha = 0.10$, ולכן בטבלה נשתמש בעמודה $1 - \alpha = 0.90$

$$\cdot \chi_{5, 0.90}^2 = 9.24 \text{ ונקבל}$$



df	.005	.01	.025	.05	.10	.25	.50	.75	.90	.95	.975	.99	.995
1	0.00004	0.00016	0.00098	0.0039	0.0158	0.102	0.455	1.32	2.71	3.84	5.02	6.63	7.88
2	0.0100	0.0201	0.0506	0.103	0.211	0.575	1.39	2.77	4.61	5.99	7.38	9.21	10.6
3	0.0717	0.115	0.216	0.352	0.584	1.21	2.37	4.11	6.25	7.81	9.35	11.3	12.8
4	0.207	0.297	0.484	0.711	1.06	1.92	3.36	5.39	7.78	9.49	11.1	13.3	14.9
5	0.412	0.554	0.831	1.15	1.61	2.67	4.35	6.63	9.24	11.1	12.8	15.1	16.7
6	0.676	0.872	1.24	1.64	2.20	3.45	5.35	7.84	10.6	12.6	14.4	16.8	18.5
7	0.989	1.24	1.69	2.17	2.83	4.25	6.35	9.04	12.0	14.1	16.0	18.5	20.3
8	1.34	1.65	2.18	2.73	3.49	5.07	7.34	10.2	13.4	15.5	17.5	20.1	22.0
9	1.73	2.09	2.70	3.33	4.17	5.90	8.34	11.4	14.7	16.9	19.0	21.7	23.6
10	2.16	2.56	3.25	3.94	4.87	6.74	9.34	12.5	16.0	18.3	20.5	23.2	25.2
11	2.60	3.05	3.82	4.57	5.58	7.58	10.3	13.7	17.3	19.7	21.9	24.7	26.8
12	3.07	3.57	4.40	5.23	6.30	8.44	11.3	14.8	18.5	21.0	23.3	26.2	28.3

$$\chi_{\text{stat}}^2 > \chi_{df, 1-\alpha}^2 \implies \text{דוחים את } H_0$$

בדוגמה: $df = 5$, $\alpha = 0.10$, ולכן בטבלה נשתמש בעמודה $1 - \alpha = 0.90$

$$\cdot \chi_{5, 0.90}^2 = 9.24 \text{ ונקבל}$$



אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מבחן χ^2 להתפלגות רציפה

כאשר ההתפלגות רציפה, נבחר גבולות כך שכל מקטע יקבל הסתברות שווה לפי ההתפלגות התאורטית.



כאשר ההתפלגות רציפה, נבחר גבולות כך שכל מקטע יקבל הסתברות שווה לפי ההתפלגות התאורטית.

כלומר, עבור k מקטעים:

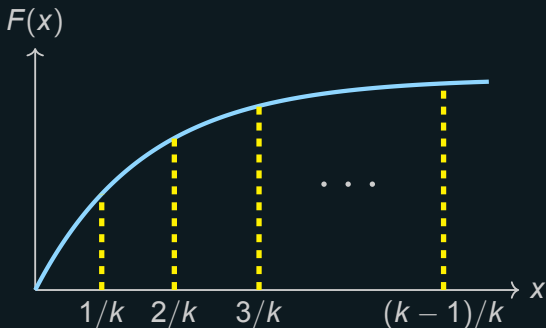
$$F(x_1) = \frac{1}{k}, \quad F(x_2) = \frac{2}{k}, \quad \dots \quad F(x_{k-1}) = \frac{k-1}{k}$$



כאשר ההתפלגות רציפה, נבחר גבולות כך שכל מקטע יקבל הסתברות שווה לפי ההתפלגות התאורטית.

כלומר, עבור k מקטעים:

$$F(x_1) = \frac{1}{k}, \quad F(x_2) = \frac{2}{k}, \quad \dots \quad F(x_{k-1}) = \frac{k-1}{k}$$





אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מבחן χ^2 - חלוקה למקטעים

במבחן χ^2 מחלקים את המרחב למקטעים, או "דליים".



במבחן χ^2 מחלקים את המרחב למקטעים, או "דליים".

- במקרה בדיד - כל ערך הוא דלי.
- במקרה רציף - צריך לבחור גבולות למקטעים.
- נרצה שבכל מקטע יהיו מספיק תצפיות צפויות.



במבחן χ^2 מחלקים את המרחב למקטעים, או "דליים".

- במקרה בדיד - כל ערך הוא דלי.
- במקרה רציף - צריך לבחור גבולות למקטעים.
- נרצה שבכל מקטע יהיו מספיק תצפיות צפויות.

כללי אצבע

- לפחות 5 אינטרוולים.
- בכל מקטע נרצה בערך:

$$np_j \geq 10$$

- במקרה רציף נוח לבחור מקטעים עם הסתברות שווה:

$$p_j = \frac{1}{k}$$



אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מבחן Kolmogorov-Smirnov

מבחן KS מתאים במיוחד להשוואה בין נתונים לבין התפלגות רציפה.



מבחן KS מתאים במיוחד להשוואה בין נתונים לבין התפלגות רציפה.
נסדר את התצפיות בסדר עולה:

$$x_1 \leq x_2 \leq \dots \leq x_n$$



מבחן KS מתאים במיוחד להשוואה בין נתונים לבין התפלגות רציפה.
נסדר את התצפיות בסדר עולה:

$$x_1 \leq x_2 \leq \dots \leq x_n$$

נחשב לכל תצפית את ערך ההתפלגות המשוערת $F(x_i)$.



מבחן KS מתאים במיוחד להשוואה בין נתונים לבין התפלגות רציפה.
נסדר את התצפיות בסדר עולה:

$$x_1 \leq x_2 \leq \dots \leq x_n$$

נחשב לכל תצפית את ערך ההתפלגות המשוערת $F(x_i)$. כמו כן נחשב
עבור כל תצפית:

$$D_i^+ = \frac{i}{n} - F(x_i), \quad D_i^- = F(x_i) - \frac{i-1}{n}$$



מבחן KS מתאים במיוחד להשוואה בין נתונים לבין התפלגות רציפה.
נסדר את התצפיות בסדר עולה:

$$x_1 \leq x_2 \leq \dots \leq x_n$$

נחשב לכל תצפית את ערך ההתפלגות המשוערת $F(x_i)$. כמו כן נחשב
עבור כל תצפית:

$$D_i^+ = \frac{i}{n} - F(x_i), \quad D_i^- = F(x_i) - \frac{i-1}{n}$$

הסטטיסטי הוא:

$$D = \max\{\max_i D_i^+, \max_i D_i^-\}$$



אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מבחן Kolmogorov-Smirnov - פירוש

לאחר שמחשבים את D , משווים לערך קריטי מטבלת KS.



לאחר שמחשבים את D , משווים לערך קריטי מטבלת KS.

Case	Adjusted test statistic	$1 - \alpha$				
		0.850	0.900	0.950	0.975	0.990
All Parameters known	$\left(\sqrt{n} + 0.12 + \frac{0.11}{\sqrt{n}}\right) D_n$	1.138	1.244	1.358	1.480	1.628
$N(\bar{X}(n), S^2(n))$	$\left(\sqrt{n} - 0.01 + \frac{0.85}{\sqrt{n}}\right) D_n$	0.775	0.819	0.895	0.955	1.035
$\text{Exp}(\bar{X}(n))$	$\left(\sqrt{n} + 0.26 + \frac{0.5}{\sqrt{n}}\right) \left(D_n - \frac{0.2}{n}\right)$	0.926	0.990	1.094	1.190	1.308

אם $D < D_{\text{crit}}$:



לאחר שמחשבים את D , משווים לערך קריטי מטבלת KS.

Case	Adjusted test statistic	$1 - \alpha$				
		0.850	0.900	0.950	0.975	0.990
All Parameters known	$\left(\sqrt{n} + 0.12 + \frac{0.11}{\sqrt{n}}\right) D_n$	1.138	1.244	1.358	1.480	1.628
$N(\bar{X}(n), S^2(n))$	$\left(\sqrt{n} - 0.01 + \frac{0.85}{\sqrt{n}}\right) D_n$	0.775	0.819	0.895	0.955	1.035
$\text{Exp}(\bar{X}(n))$	$\left(\sqrt{n} + 0.26 + \frac{0.5}{\sqrt{n}}\right) \left(D_n - \frac{0.2}{n}\right)$	0.926	0.990	1.094	1.190	1.308

אם $D < D_{\text{crit}}$:

לא דוחים את H_0 .



לאחר שמחשבים את D , משווים לערך קריטי מטבלת KS.

Case	Adjusted test statistic	$1 - \alpha$				
		0.850	0.900	0.950	0.975	0.990
All Parameters known	$\left(\sqrt{n} + 0.12 + \frac{0.11}{\sqrt{n}}\right) D_n$	1.138	1.244	1.358	1.480	1.628
$N(\bar{X}(n), S^2(n))$	$\left(\sqrt{n} - 0.01 + \frac{0.85}{\sqrt{n}}\right) D_n$	0.775	0.819	0.895	0.955	1.035
$\text{Exp}(\bar{X}(n))$	$\left(\sqrt{n} + 0.26 + \frac{0.5}{\sqrt{n}}\right) \left(D_n - \frac{0.2}{n}\right)$	0.926	0.990	1.094	1.190	1.308

אם $D < D_{\text{crit}}$:

לא דוחים את H_0 .

אם $D \geq D_{\text{crit}}$:



לאחר שמחשבים את D , משווים לערך קריטי מטבלת KS.

Case	Adjusted test statistic	$1 - \alpha$				
		0.850	0.900	0.950	0.975	0.990
All Parameters known	$\left(\sqrt{n} + 0.12 + \frac{0.11}{\sqrt{n}}\right) D_n$	1.138	1.244	1.358	1.480	1.628
$N(\bar{X}(n), S^2(n))$	$\left(\sqrt{n} - 0.01 + \frac{0.85}{\sqrt{n}}\right) D_n$	0.775	0.819	0.895	0.955	1.035
$\text{Exp}(\bar{X}(n))$	$\left(\sqrt{n} + 0.26 + \frac{0.5}{\sqrt{n}}\right) \left(D_n - \frac{0.2}{n}\right)$	0.926	0.990	1.094	1.190	1.308

אם $D < D_{\text{crit}}$:

לא דוחים את H_0 .

אם $D \geq D_{\text{crit}}$:

דוחים את H_0 .



אוניברסיטת בן-גוריון בנגב
جامعة بن غوريون في النقب
Ben-Gurion University of the Negev

מימוש ב-Python



https://colab.research.google.com/drive/1iR0pBdbcYTItFBo45CeO_ZyHeM6rx_b_t