

# פתרון תרגיל 1

## שאלה 1:

ראינו שהמעריך  $\hat{n}_U(x) = 2^x - 1$ , כאשר  $x$  הוא מונה מוריס, הוא מעריך בלתי מוטה של הספירה האמיתית של  $n$ .

א. צ"ל את ה-MLE,  $\hat{n}_{MLE}(x)$ , כאשר ערך ה-Morris Counter הוא  $x = 1, \dots, 10$ .

$$\hat{n}_{MLE}(X) = \underset{n}{\operatorname{argmax}} f(X; n)$$

צ"ל למצא עבור כל  $x_i$  את הערך של  $n$ , עבורו הסיכוי לקבל  $x = x_i$  הוא הגבוה ביותר.

הערך של  $f(x; n)$  תלוי במצב הקודם שהיה, או שהאיבר החדש גרם להעלאה של  $x$  או שלא.

הסתברות המקרה שבו העלנו את  $x$  היא  $2^{-(x-1)}$ , וזו כופלת את ההסתברות של המצב הקודם, כלומר,  $f(x-1; n-1)$ . באותו אופן, הסתברות המקרה שלא העלנו את  $x$  היא  $(1 - 2^{-x})$  והיא כופלת את  $f(x; n-1)$ . קיבלנו את הנוסחה הרקורסיבית הבאה:

$$f(x; n) = (1 - 2^{-x})f(x; n-1) + 2^{-(x-1)}f(x-1; n-1)$$

נשים לב שבנוסף אנחנו יודעים את תנאי ההתחלה (עבור האיבר הראשון הסיכוי להגיע ל- $x = 1$  הוא בדיוק 1).

$$f(x = 1, n = 1) = 1$$

בנוסף, נשים לב לאבחנה שלא ייתכן מצב שבו הגענו ל- $x$  יותר גבוה מ- $n$  (אנחנו מגדילים את הערך של  $x$  פעם אחת לכל היותר עבור כל  $n$  והם מתחילים מאותו ערך...).

$$f(x > n, n) = 0$$

אני מניח שהחלק הבא לא היה נדרש והוא מובא פה בקצרה לשם שלמות התשובה:

יהי  $x$  כלשהו, עבור כל  $n \geq \hat{n}_{MLE}$ , נוכיח כי  $f(x; n) \geq f(x; n+1)$  כלומר  $\Delta(x, n) = f(x; n) - f(x; n+1) \geq 0$  בערכים עבור  $x$  מסוים נוכל להפסיק לבדוק (מאחר וזהו ה-MLE הדרוש).  
נוכיח באינדוקציה על  $x$ : עבור  $x = 1$  נקבל שהפונקציה מצטמצמת ל- $f(x = 1, n) = \frac{1}{2^{n-1}}$  ולכן ברור כי היא יורדת החל מ- $\hat{n}_{MLE} = 1$ . נניח כי הטענה נכונה לכל  $x < x'$  ונוכיח אותה עבור  $x = x'$ . נניח כי עבור  $x'$ , קיים ה- $\hat{n}_{MLE}$  המתאים לו. ונוכיח באינדוקציה על  $n$ :  
נשים לב כי מאחר וקיים ערך  $\hat{n}_{MLE}$  שהוא מקסימאלי, עבור כל  $n \neq \hat{n}_{MLE}$  נקבל כי  $f(x, n) \leq f(x, \hat{n}_{MLE})$  ובפרט עבור  $n = \hat{n}_{MLE} + 1$ . נניח כי הטענה נכונה לכל  $k < n$  ונוכיח אותה עבור  $n$ .

$$\begin{cases} f(x; n) = (1 - 2^{-x})f(x; n-1) + 2^{-(x-1)}f(x-1; n-1) \\ f(x; n+1) = (1 - 2^{-x})f(x; n) + 2^{-(x-1)}f(x-1; n) \end{cases}$$

$$\begin{aligned} \Rightarrow \Delta(x, n) &= f(x; n + 1) - f(x; n) \\ &= (1 - 2^{-x})(f(x; n) - f(x; n - 1)) \\ &\quad + 2^{-(x-1)}(f(x - 1; n) - f(x - 1; n - 1)) \\ &= (1 - 2^{-x})\Delta(x, n - 1) + 2^{-(x-1)}\Delta(x - 1, n - 1) \end{aligned}$$

ע"פ הנחת האינדוקציה (על  $n$ ) נקבל כי החלק הראשון  $\Delta(x, n - 1) \leq 0$  וכן מאחר ו- $\hat{n}_{MLE}$  היא פונקציה לא יורדת, ע"פ הנחת האינדוקציה (על  $x$ ) נקבל כי  $\Delta(x - 1, n - 1) \leq 0$  ולכן:

$$\Delta(x, n) = f(x; n + 1) - f(x; n) \leq 0$$

← מצאנו כי עבור  $x$  מסוים ניתן לחשב את הערכים של  $f(x, n)$  עד הערך הראשון שלא עולה על קודמו, וזהו ה- $\hat{n}_{MLE}$ .

נחשב באמצעות תכנות דינאמי את המטריצה הנ"ל ונמצא את המקסימום עבור כל  $x$ .

התוצאות:

$x$	$\hat{n}_{MLE}$	Max-Likelihood
1	1	1
2	3	0.625
3	8	0.523670197
4	19	0.486695161
5	39	0.470369477
6	80	0.462512782
7	162	0.45869213
8	325	0.456812012
9	652	0.455876987
10	1306	0.45541105

הקוד מצורף בסוף התשובות (נספח א') – כולל את סעיפים א' ו-ב' של שאלה 1.

ב. נחשב את הערכים הבאים:

(a)  $Bias(\hat{n}_{MLE}, n) = E[\hat{n}_{MLE}] - n$

(b)  $MSE(\hat{n}_{MLE}, n) = E[(\hat{n}_{MLE} - n)^2]$   
 $= E[\hat{n}_{MLE}^2 - 2 \cdot \hat{n}_{MLE} \cdot n + n^2] = E[\hat{n}_{MLE}^2] - 2n \cdot E[\hat{n}_{MLE}] + n^2$

(c)  $NRMSE(\hat{n}_{MLE}, n) = \frac{\sqrt{MSE(\hat{n}_{MLE})}}{n}$

(d)  $CV[\hat{n}] = \frac{\sigma}{\mu}$  ;  $\sigma = \sqrt{V[\hat{n}]}$

ע"פ מה שראינו בשיעור,  $V[\hat{n}] = \frac{3}{2}n^2 + \frac{3}{2}n + 1 - (n + 1)^2 = \frac{1}{2}n^2 - \frac{1}{2}n$ ,

$$\Rightarrow \sigma = \sqrt{\frac{1}{2}(n^2 - n)}$$

וכן, עבור מעריך בלתי מוטה  $\mu = E[\hat{n}] = n$  ונקבל:

$$CV[\hat{n}] = \frac{\sqrt{\frac{1}{2}(n^2 - n)}}{n} = \sqrt{\frac{n - 1}{2n}}$$

$n$	$Bias(\hat{n}_{MLE}, n)$	$MSE(\hat{n}_{MLE})$	$NRMSE(\hat{n}_{MLE})$	$CV[\hat{n}]$
1	0.0	0.0	0.0	0.0
2	0.0	1.0	0.5	0.5
3	0.125	4.125	0.677003200386	0.57735026919
4	0.328125	9.484375	0.769917812172	0.612372435696
5	0.580078125	16.966796875	0.823815437462	0.632455532034
6	0.862091064453	26.4124450684	0.856550657975	0.645497224368
7	1.16192817688	37.68080616	0.876924195174	0.654653670708
8	1.47153985128	50.6706994362	0.889791929999	0.661437827766
9	1.78563172738	65.320132343	0.898009680878	0.666666666667
10	2.10075975438	81.5989877533	0.903321580354	0.67082039325

ג. נוכיח כי  $MSE[\hat{\theta}] = Var[\hat{\theta}] + Bias(\hat{\theta}, \theta)^2$  לכל מעריך  $\hat{\theta}$  של  $\theta$ .

אנו יודעים כי:

$$Bias(\hat{\theta}, \theta) = E[\hat{\theta}] - \theta \Rightarrow Bias(\hat{\theta}, \theta)^2 = (E[\hat{\theta}])^2 - 2 \cdot \theta \cdot E[\hat{\theta}] + \theta^2$$

$$Var[\hat{\theta}] = E[(\hat{\theta} - E[\hat{\theta}])^2] = E[\hat{\theta}^2] - (E[\hat{\theta}])^2$$

$$MSE(\hat{\theta}, \theta) = E[(\hat{\theta} - \theta)^2] = E[\hat{\theta}^2 - 2 \cdot \theta \cdot \hat{\theta} + \theta^2] = E[\hat{\theta}^2] - 2 \cdot \theta \cdot E[\hat{\theta}] + \theta^2$$

ולכן:

$$\begin{aligned} Var[\hat{\theta}] + Bias(\hat{\theta}, \theta)^2 &= E[\hat{\theta}^2] - (E[\hat{\theta}])^2 + (E[\hat{\theta}])^2 - 2 \cdot \theta \cdot E[\hat{\theta}] + \theta^2 \\ &= E[\hat{\theta}^2] - 2 \cdot \theta \cdot E[\hat{\theta}] + \theta^2 = MSE(\hat{\theta}, \theta) \end{aligned}$$

$$\Rightarrow Var[\hat{\theta}] + Bias(\hat{\theta}, \theta)^2 = MSE(\hat{\theta}, \theta) \blacksquare$$

ד. נגדיר  $A = \frac{1}{k} \sum_{i=1}^k \hat{n}_{MLE}(x_i)$  ו-  $B = \frac{1}{k} \sum_{i=1}^k \hat{n}_U(x_i)$  צ"ל:  $NRMSE(A)$  ו-  $NRMSE(B)$ .

ע"פ מה שלמדנו בשיעור הראשון, כאשר לוקחים מעריך שהוא ממוצע של  $k$  מעריכים בלתי תלויים התוחלת נשארת זהה וה- Variance יורד פי  $k$ , ולכן ה-  $CV$  יורד פי  $\sqrt{k}$ .

כאמור בסעיף ב',  $CV[\hat{n}] = NRMSE(\hat{n})$  ולכן נקבל כי:  $NRMSE(B) = CV(B) = \frac{CV(\hat{n})}{\sqrt{k}}$

$$NRMSE(B) = \frac{0.6614}{\sqrt{k}} \leftarrow n = 8 \text{ ועבור}$$

לפי סעיף ג' אנו יודעים כי  $Var[A] = MSE(A, n) - Bias(A, n)^2$ ,

בנוסף  $Bias(A, n) = E[A] - n = E[\hat{n}_{MLE}] - n = Bias(\hat{n}_{MLE}, n)$

$$\begin{aligned} \Rightarrow NRMSE(A) &= \frac{\sqrt{MSE(A)}}{n} = \frac{\sqrt{Var[A] + Bias(A, n)^2}}{n} = \frac{\sqrt{\frac{1}{k} Var[\hat{n}_{MLE}] + Bias(\hat{n}_{MLE}, n)^2}}{n} \\ &= \frac{\sqrt{\frac{1}{k} (MSE(\hat{n}_{MLE}, n) - Bias(\hat{n}_{MLE}, n)^2) + Bias(\hat{n}_{MLE}, n)^2}}{n} \end{aligned}$$

$$NRMSE(A) = \sqrt{\frac{1}{k} \cdot 0.7579 + 0.0338} \leftarrow n = 8 \text{ ועבור}$$

## שאלה 2:

א. נוכיח כי בכל שלב בעיבוד ה-stream נקבל כי  $\hat{c}_i \leq c_i$ .

נסמן ב- $c_i^k$  וב- $\hat{c}_i^k$  את הערכים אותם יחזירו האלגוריתמים, לאחר עיבוד של  $k$  האיברים הראשונים.

נוכיח באמצעות אינדוקציה על  $n$  (מספר האיברים אותם עיבדנו) כי לאחר עיבוד כל איבר נקבל  $\hat{c}_i^n \leq c_i^n$  (ולכן נקבל כי באופן כללי  $\hat{c}_i \leq c_i$ ).

עבור המצב ההתחלתי  $n = 0$ : הערך  $c_i^0$  ע"פ הגדרתו הוא 0, וכן, מאחר ולא קיים counter האלגוריתם  $MG \pm$  יחזיר  $\hat{c}_i^0 = 0$ .

נניח כי הטענה נכונה עבור  $n = k$ , כלומר לאחר עיבוד של  $k$  איברים מה-stream קיבלנו כי:

$$\hat{c}_i^k \leq c_i^k$$

וכעת, נוכיח אותה עבור  $n = k + 1$ .

בהינתן שקיבלנו  $(j, \Delta)$ , נחלק את העולם לשני מצבים:

**אם  $j \neq i$  אזי**, הערך האמיתי של  $c_i$  לא ישתנה ונקבל כי  $c_i^{k+1} = c_i^k$ , וכן עבור הערך המקורב:

- אם קיים counter ל- $j$  אזי בהתאם ל- $\Delta$  נעלה / נוריד אותו באחד (והדבר לא ישפיע על  $\hat{c}_i$ ) ולכן נקבל  $\hat{c}_i^{k+1} = \hat{c}_i^k$ .
- אם לא קיים counter ל- $j$  אזי:
  1. אם  $\Delta = -1$  לא נבצע כלום ולכן נקבל  $\hat{c}_i^{k+1} = \hat{c}_i^k$ .
  2. אחרת אם  $\Delta = +1$ , נוריד את כל ה-counter הקיימים ב-1 (אם  $\hat{c}_i^k = 0$  אזי הוא יישאר 0) ונקבל כי  $\hat{c}_i^{k+1} \leq \hat{c}_i^k$ .

ובאופן כללי, נקבל  $\hat{c}_i^{k+1} \leq \hat{c}_i^k$ .

$$\Rightarrow \hat{c}_i^{k+1} \leq \hat{c}_i^k \leq c_i^k = c_i^{k+1}$$

$$\Rightarrow \hat{c}_i^{k+1} \leq c_i^{k+1}$$

**אחרת,  $j = i$  אזי**, הערך האמיתי של  $c_i$  ישתנה ונקבל  $c_i^{k+1} = \max\{0, c_i^k + \Delta\}$ , וכן עבור הערך המקורב:

- אם קיים counter ל- $i$  אזי בהתאם ל- $\Delta$  נעלה / נוריד אותו ונקבל כי  $\hat{c}_i^{k+1} = \hat{c}_i^k + \Delta$ 
  - ולכן נקבל כי (מאחר ו- $0 < \hat{c}_i^k \leq c_i^k$  אזי  $c_i^{k+1} = c_i^k + \Delta$ )

$$\Rightarrow \hat{c}_i^{k+1} = \hat{c}_i^k + \Delta \leq c_i^k + \Delta = c_i^{k+1}$$

$$\Rightarrow \hat{c}_i^{k+1} \leq c_i^{k+1}$$

- אם לא היה קיים counter ל- $i$  אזי הערך המקורב  $\hat{c}_i$  יישאר זהה ולכן נקבל  $\hat{c}_i^{k+1} = \hat{c}_i^k = 0$ . נפצל שוב את העולם לשני מקרים:
  - אם  $\Delta = +1$ :

$$\Rightarrow \hat{c}_i^{k+1} = \hat{c}_i^k \leq c_i^k < c_i^k + 1 = c_i^{k+1}$$

$$\Rightarrow \hat{c}_i^{k+1} \leq c_i^{k+1}$$

אחרת, אם  $\Delta = -1$  אזי: הערך האמיתי יהיה  $c_i^{k+1} = \max\{0, c_i^k - 1\} \geq 0$  וכן הערך המקורב  
כאמור יהיה  $\hat{c}_i^{k+1} = 0$  ולכן:

$$\Rightarrow \hat{c}_i^{k+1} = 0 \leq c_i^{k+1}$$

קיבלנו כי בכל המקרים לעיל  $\hat{c}_i^{k+1} \leq c_i^{k+1}$  ולכן, ע"פ הנחת האינדוקציה המתמטית הטענה נכונה  
לכל  $k$  טבעי, ובפרט ל- $k = n$ , כלומר:

$$\Rightarrow \hat{c}_i^n \leq c_i^n$$

$$\Rightarrow \hat{c}_i \leq c_i \blacksquare$$

ב. צ"ל את החסם ההדוק העליון של  $c_i - \hat{c}_i$ .

נשים לב כי הפער יגדל כאשר נקבל איבר  $(j, \Delta)$  כך ש- $\hat{c}_j$  לא נמצא וכן  $\Delta = +1$ , ובמהלך זה נוריד  
סה"כ  $k$  מהסכום הכולל ונתעלם מאיבר נוסף. נתעלם במקרה זה מסה"כ  $k + 1$  הופעות בלתי  
ספורות, נגדיר אותו בתור decrement ונסמן את מספר הפעמים שהוא קורה ב- $d$ . בנוסף, הפער  
יקטן כאשר נקבל  $(i, \Delta)$  כש- $\hat{c}_i$  לא נמצא וכן  $\Delta = -1$ . בכל שאר הצעדים הפער לא ישתנה.

ההפרש המרבי עבור מונה בודד:  $c_i - \hat{c}_i \leq d$ .

נסמן כעת:  $m = \sum_i c_i$  וכן,  $m' = \sum_i \hat{c}_i$ . ונגדיר שני משתני עזר:  $\Delta_+$  - מספר הפעמים בהם קיבלנו  
איבר עם  $\Delta = +1$ , וכן  $\Delta_-$  - מספר הפעמים בהם קיבלנו איבר עם  $\Delta = -1$  והוא אכן הוריד את הערך  
של המונה האמיתי  $c_i$  ב-1 (כלומר לפניו התקיים  $c_i > 0$ ).

$$\Rightarrow m = \Delta_+ - \Delta_-$$

נסמן ב- $d$  את מספר האיברים שבהם  $\Delta = -1$  וכתוצאה ממעבר עליהם השתנה הערך של  $\hat{c}$ .

$$\Rightarrow m - m' = d(k + 1) - (\Delta_- - d)$$

$$\Rightarrow \Delta_+ - \Delta_- - m' = d(k + 1) - (\Delta_- - d)$$

$$\Rightarrow \Delta_+ - m' = d(k + 1) + d$$

$$\Rightarrow d = \frac{\Delta_+ - m' - d}{k + 1}$$

$$\Rightarrow c_i - \hat{c}_i \leq d = \frac{\Delta_+ - m' - d}{k + 1}$$

אנחנו כמובן יכולים לשמור במהלך המעבר את שני המונים (אחד עבור  $\Delta_+$  והשני עבור  $d$ ) ולסכום  
את כל המונים  $\hat{c}_i$  כדי להגיע ל- $m'$ .

במידה ולא קיבלנו איבר עם  $\Delta = -1$  קיבלנו רדוקציה של הבעיה והאלגוריתם ל-MG והוכחנו בכיתה  
שבמקרה זה החסם הינו הדוק ( $\Delta_+ = m, d = 0$   $\Leftarrow$ ). וכן, ניתן לחשוב על מקרה בו כל פעם  
שמבצעים decrement מונה בודד  $\hat{c}_x$  בטוח מושפע, וב-stream לא קיימים איברים בעלי  $\Delta = -1$  (או  
שהם תמיד השפיעו גם על  $\hat{c}$ ) אזי במקרה זה אכן נקבל  $c_x - \hat{c}_x = d$  ולכן החסם הדוק.

## שאלה 3:

א. צ"ל מעריך בלתי מוטה  $\hat{c}$  לגודל  $c$  (מספר הפקטות) ב-flow.

המעריך  $\hat{c}_i$  עבור  $c_i$  (המתאים ל-flow  $i$ ), יחזיר במידה וקיים מונה בעל הערך  $x$  עבור ה-flow את  $\frac{x}{p}$  ואם לא קיים יחזיר 0.

נראה כי  $E[\hat{c}] = c$ : נסתכל על flow בודד, ונשים לב שההסתברות לדגום פקטה היא  $p$  ואינה תלויה בקלט. זוהי התפלגות בינומית ולכן  $x \sim B(c_i, p)$ .

$$\Rightarrow E[\hat{c}_i] = E\left[\frac{x}{p}\right] = \frac{c_i p}{p} = c_i$$

ב. צ"ל את ה- $Var[\hat{c}]$ .

שוב נסתכל על flow בודד:

$$Var[\hat{c}_i] = Var\left[\frac{x}{p}\right] = \frac{1}{p^2} \cdot Var[x] = \frac{1}{p^2} \cdot (c_i p (1 - p)) = c_i \cdot \frac{1 - p}{p}$$

ג. צ"ל את  $CV[\hat{c}]$ .

$$CV[\hat{c}] = \frac{\sqrt{V[\hat{c}]}}{E[\hat{c}]} = \sqrt{c_i \cdot \frac{1 - p}{p} \frac{1}{c_i^2}} = \sqrt{\frac{1 - p}{c_i p}}$$

ד. צ"ל שסיכומי NetFlow ניתנים לאיחוד.

נניח כי ישנם שני stream, כאשר בהתבוננות על flow בודד ה-stream הראשון מחזיר  $\hat{c}_1$  עבור  $c_1$  פקטות ב-flow הנ"ל והשני מחזיר  $\hat{c}_2$  עבור  $c_2$  פקטות ב-flow הנ"ל בהתאמה.

עבור flow בודד נגדיר את המיזוג כך (כאשר כמובן אין צורך להוסיף מונים אם בשני ה-stream לא נוצר מונה עבור flow מסוים):

$$\hat{c} = \hat{c}_1 + \hat{c}_2$$

נשים לב שבמקרה זה, עבור stream מחובר רציף היינו מקבלים (ע"פ סעיף א'):

$$E[\hat{c}] = c_1 + c_2$$

וכן עבור איחוד של שני ה-streamים ( $\hat{c}_1$  ו- $\hat{c}_2$  בלתי תלויים):

$$E[\hat{c}] = E[\hat{c}_1] + E[\hat{c}_2] = c_1 + c_2 \quad \blacksquare$$

ה. בהתחשב ב-stream בעל  $m$  פקטות, צ"ל איך לחלק את הפקטות ל-flowים בכדי למקסם את כמות המונים.

נסתכל על flow בודד, ונמצא מה ההסתברות לפתוח counter חדש כפונקציה של מיקום הפקטה ב-flow (הסיכוי שכן דגמנו אותה אבל לא דגמנו את כל הקודמות):

$$Pr[\text{new counter on packet } i] = p \cdot (1 - p)^{i-1}$$

וכן אם נסכום על כל הפקטות ב-stream אזי מספר המונים יהיה (עבור  $k$  flow):

$$n = \sum_{j=1}^k \sum_{i=1}^{c_k} \Pr[\text{new counter on packet } i] = \sum_{j=1}^k \sum_{i=1}^{c_k} p \cdot (1-p)^{i-1}$$

ברור כי ההסתברות עבור כל פקטה לפתוח *counter* חדש יורדת עם מיקומה ב-*stream* ולכן נעדיף "לנצל" אותה כאשר היא במקסימום, כלומר, אם נחלק כל פקטה ל-*flow* שונה אזי נקבל כי ההסתברות לפתוח *counter* חדש עבור כל פקטה היא בדיוק  $p$ , ולכן נקבל את המקסימום של  $n$ .

נקבל כי:

$$n = \sum_{j=1}^k \sum_{i=1}^{c_k} p \cdot (1-p)^{i-1} = \sum_{j=1}^c \sum_{i=1}^1 p \cdot (1-p)^{i-1} = \sum_{j=1}^c p = cp \blacksquare$$

## נספח א' (קוד python לשאלה מספר 1 סעיפים א' ו-ב):

```

MAX_X = 10 # the maximum value for x
MAX_N = 10 # the maximum value for n (for computing section B)
# Using dynamic programming we compute each value of f(x,n) once and store it inside this table:
table = [[] for x in xrange(MAX_X)]
# a row in the table holds all values of possibilities for where x is the (row-index + 1)
# the index inside the row corresponds to value of n.
def f(x, n):
    # This function retrieves the value if previously computed, else computes it first.
    # f(x;n) = table[x-1][n-1]
    if len(table[x-1]) < n:
        fill_row(x-1, n)
    return table[x-1][n-1]

def compute(x, n):
    # This function computes the value of f(x,n).
    if x == 1 and n == 1:
        f_xn = 1.0
    elif x > n:
        f_xn = 0.0
    else:
        f_xn = (1 - 2**(-x)) * f(x, n - 1)
        if x > 1:
            f_xn += 2**(-(x - 1)) * f(x - 1, n - 1)
    return f_xn

def fill_row(i, max_n = -1):
    # This function fills the row (which corresponds to a value of x) until we either
    # reach the maximum likelihood for that value of x or until we reach max_n (inorder
    # to calculate another value: f(x, max_n) which is needed)
    x = i + 1 # the value of x
    last = 0 # saves the last value
    value = last # saves the current value
    n = len(table[i]) + 1 # the start n (the first unyet calculated value)
    while not (last > value or ((max_n != -1) and (n > max_n))):
        last = value # update the last value
        value = compute(x, n) # get the computed value for f(x, n)
        table[i].append(value) # save the value in the table
        n = n + 1 # increase the value of n

def fill_table(max_x = MAX_X):
    # This function fills the entire table up to the value of x = max_x
    for i in xrange(max_x):
        fill_row(i)

def print_sum():
    # prints the outcome of the run
    print "\n\t n_mle\tMax-Likelihood"
    print "-" * 30
    n_mle = []
    for i in xrange(MAX_X):
        max_value = max(table[i])
        n_value = table[i].index(max(table[i])) + 1
        print i+1, "\t", n_value, "\t", max_value
        n_mle.append(n_value)
    print ""

    print "\n\t a\t b\t c\t d"
    print "-" * 40
    for j in xrange(MAX_N):
        n = j + 1
        col = [f(i+1, n) for i in xrange(n)]
        E_mle = sum([n_mle[i] * p for i, p in enumerate(col)])
        E_mle2 = sum([n_mle[i] ** 2 * p for i, p in enumerate(col)])
        a = E_mle - n
        b = E_mle2 - 2 * n * E_mle + n ** 2
        c = b ** 0.5 / n
        d = ((n - 1) / (2.0 * n)) ** 0.5
        print n, "\t", a, "\t", b, "\t", c, "\t", d
    print ""

def main():
    fill_table()
    print_sum()
if __name__ == "__main__":
    main()
import os
os.system("pause")

```