

Στατιστική Απόσταση

Για τους παρακάτω αλγορίθμους, να υπολογιστεί η στατιστική απόσταση της εξόδου τους από την ομοιόμορφη κατανομή U στο $S = \{0, 1, 2, \dots, A - 1\}$.

Sampler 1. $n := \lceil \log_2 A \rceil$

$$\begin{aligned} x_0, x_1, \dots, x_{n-1} &\leftarrow \{0, 1\} \\ y &:= \sum_{i=0}^{n-1} 2^i \cdot x_i \\ \text{return } y \end{aligned}$$

Sampler 2. $x_0, x_1, \dots, x_{A-1} \leftarrow \{0, 1\}$

$$\begin{aligned} y &:= \sum_{i=0}^{A-1} x_i \\ \text{return } y \end{aligned}$$

Sampler 3. $n := \lceil \log_2 A \rceil$

repeat:

$$\begin{aligned} x_0, x_1, \dots, x_{n-1} &\leftarrow \{0, 1\} \\ y &:= \sum_{i=0}^{n-1} 2^i \cdot x_i \\ \text{if } y < A: \text{return } y \end{aligned}$$

Sampler 1. Ορίζουμε $B = 2^n$, και ελέγχουμε ότι η έξοδος του sampler είναι μια τυχαία μεταβλητή Y που ακολουθεί την ομοιόμορφη κατανομή στο $\{0, 1, 2, \dots, B - 1\}$. Παρατηρούμε επίσης ότι $B \geq A$, άρα το σύνολο τιμών της Y υπερκαλύπτει αυτό της U . Από τον ορισμό της στατιστικής απόστασης έχουμε:

$$\begin{aligned} \Delta(U, Y) &= \frac{1}{2} \sum_{i=0}^B |\Pr(U = 1) - \Pr(Y = i)| \\ &= \frac{1}{2} \sum_{i=0}^A |\Pr(U = 1) - \Pr(Y = i)| + \frac{1}{2} \sum_{i=A}^B |\Pr(U = 1) - \Pr(Y = i)| \\ &= \frac{1}{2} \sum_{i=0}^A \left| \frac{1}{A} - \frac{1}{B} \right| + \frac{1}{2} \sum_{i=A}^B \left| 0 - \frac{1}{B} \right| \\ &= \frac{1}{2} A \left| \frac{1}{A} - \frac{1}{B} \right| + \frac{1}{2} (B - A) \left| 0 - \frac{1}{B} \right| \\ &= \frac{1}{2} A \left(\frac{1}{A} - \frac{1}{B} \right) + \frac{1}{2} (B - A) \frac{1}{B} \\ &= \frac{1}{2} \left(\frac{A}{A} - \frac{A}{B} \right) + \frac{1}{2} \frac{B - A}{B} \\ &= \frac{1}{2} \left(1 - \frac{A}{B} + 1 - \frac{A}{B} \right) \\ &= 1 - \frac{A}{B} \end{aligned}$$

Οπως αναμένουμε, όταν $A = B$ η στατιστική απόσταση είναι μηδενική, ενώ όταν $A = 2^k - 1$ η διαφορά είναι σχεδόν $\frac{1}{2}$. Όταν το A είναι κοντά στο B , παρατηρούμε επίσης ότι η απόσταση είναι αμελητέα ως προς το n .

Sampler 2. Αναγνωρίζουμε ότι η κατανομή Y του sampler είναι η διωνυμική με παραμέτρους $p = q = \frac{1}{2}$ και $n = A$ το πλήθος δοκιμές. Ξέρουμε ότι η κατανομή αυτή έχει σχήμα καμπύλης, άρα πιστεύουμε ότι μακριά

από το μέσο όρο, θα εμφανίζει χαμηλή πιθανότητα. Αφού ο μέσος όρος είναι $p \cdot A = \frac{A}{2}$, επιλέγουμε να εξετάσουμε τις τιμές από το $\frac{3A}{4}$ ως το A . Προφανώς για τη στατιστική απόσταση θα ισχύει ότι:

$$\begin{aligned}
\Delta(U, Y) &= \frac{1}{2} \sum_{i=0}^A |\Pr(U=1) - \Pr(Y=i)| \\
&\leq \frac{1}{2} \sum_{i=3A/4}^A |\Pr(U=1) - \Pr(Y=i)| \quad (\text{Παραλείπουμε θετικούς όρους, το άθροισμα δεν αυξάνεται}) \\
&\leq \frac{1}{2} \sum_{i=3A/4}^A (\Pr(U=1) - \Pr(Y=i)) \quad (\text{Αφαιρούμε απόλυτα, άρα το άθροισμα δεν αυξάνεται}) \\
&= \frac{1}{2} \sum_{i=3A/4}^A \Pr(U=1) - \frac{1}{2} \sum_{i=3A/4}^A \Pr(Y=i) \\
&= \frac{1}{2} \cdot \frac{1}{4} - \frac{1}{2} \sum_{i=3A/4}^A \Pr(Y=i) \\
&= \frac{1}{8} - \frac{1}{2} \sum_{i=3A/4}^A \Pr(Y=i)
\end{aligned}$$

Για να έχουμε λοιπόν μια εκτίμηση για την απόσταση, μένει να υπολογίσουμε (προσεγγιστικά) το άθροισμα πιθανοτήτων της Y για τιμές από $3A/4$ ως A , ή ισοδύναμα την πιθανότητα $P[Y \geq \frac{3A}{4}]$. Από τις σημειώσεις γνωρίζουμε την ανισότητα του Chebychev:

$$\Pr[|Y - E(Y)| \geq t] \leq \frac{Var[Y]}{t^2}$$

Γνωρίζουμε ότι για τη διωνυμική ο μέσος όρος $E(Y)$ είναι $n \cdot p = \frac{A}{2}$, η διακύμανση $Var[Y]$ είναι $n \cdot p \cdot q = \frac{A}{4}$. Αντικαθιστούμε για $t = \frac{A}{4}$ και έχουμε:

$$\Pr[Y \geq \frac{3A}{4}] = \Pr[Y - \frac{A}{2} \geq \frac{A}{4}] = \Pr[Y - E(Y) \geq t] \leq \Pr[|Y - E(Y)| \geq t] \leq \frac{\frac{A}{8}}{\frac{A}{4} \cdot \frac{A}{4}} = \frac{\frac{1}{2}}{\frac{A}{4}} = \frac{1 \cdot 4}{2 \cdot A} = \frac{2}{A}$$

Επιστρέφοντας στο φράγμα για τη στασιστική απόσταση έχουμε ότι:

$$\begin{aligned}
\Delta(U, Y) &= \frac{1}{2} \sum_{i=0}^A |\Pr(U=1) - \Pr(Y=i)| \\
&\leq \frac{1}{8} - \frac{1}{2} \sum_{i=3A/4}^A \Pr(Y=i) \\
&\leq \frac{1}{8} - \frac{1}{2} \frac{2}{A} \\
&= \frac{1}{8} - \frac{1}{A}
\end{aligned}$$

Άρα για μεγάλες τιμές του A , η στατιστική απόσταση είναι σημαντική, και αυξάνεται όσο μεγαλώνει το A .

Παρατίρηση: Σε τρία σημεία της λύσης μπορούμε επικαλούμενοι τη συμμετρία να πάρουμε σημαντικά καλύτερες τιμές για τα φράγματα (περίπου 3 διπλασιασμούς). Πρώτα: μπορούμε να εξετάσουμε και το διάστημα από 0 έως $\frac{A}{4}$. Μετά: μπορούμε να ισχυριστούμε ότι αφού οι πιθανότητες και των δύο κατανομών αθροίζονται στο 1, η διαφορά που έχουν στο διάστημα $[0, A]$ θα είναι συνολικά 0, άρα η διαφορά στο κεντρικό διάστημα (χωρίς απόλυτη τιμή) θα είναι η αντίθετη της διαφοράς στα άκρα (οπότε εφαρμόζοντας την απόλυτη τιμή διπλασιάζουμε τη διαφορά που είχαμε). Τέλος, στην ανισότητα Chebychev φράξαμε την πιθανότητα να ξεπεράσουμε τα $3/4$ με την πιθανότητα να απομακρυνθούμε από το $1/2$ κατά $1/4$ ή παραπάνω, η οποία λόγω συμμετρίας θα είναι περίπου διπλάσια.

- Sampler 3. Θα κάνουμε χρήση της δεσμευμένης πιθανότητας. Οι τιμές του y επιλέγονται ομοιόμορφα από το $\{0, 1, 2, \dots, B - 1\}$ αλλά επιστρέφονται μόνο εάν $y < A$. Ονομάζουμε Z την τυχαία μεταβλητή της εξόδου του sampler, και θεωρούμε την Y όπως στον πρώτο sampler. Από την κατασκευή του προγράμματος έχουμε ότι: $\Pr(Z = x) = \Pr(Y = x | Y < A)$. Από τον ορισμό της δεσμευμένης πιθανότητας:

$$\Pr(Y = x | Y < A) = \Pr(Y = x | x < A) = \frac{\Pr((Y=x) \cap (x < A))}{\Pr(Y < A)}$$

Όταν $x \geq A$ η παραπάνω πιθανότητα είναι μηδενική. Στη μη τετριμμένη περίπτωση όπου $x < A$, έχουμε $\frac{\Pr(Y=x)}{\Pr(Y < A)} = \frac{\frac{1}{B}}{\frac{A}{B}} = \frac{1}{A} \cdot \frac{B}{A} = \frac{1}{A}$.

Άρα, για $x \geq A$, $\Pr(Z = x) = 0$ και για $x < A$, $\Pr(Z = x) = \frac{1}{A}$, και η στατιστική απόσταση είναι προφανώς 0. Παρατηρούμε όμως ότι ο χρόνος εκτέλεσης δεν είναι σταθερός.