



ΔΠΜΣ ΕΠΙΣΤΗΜΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

ΜΑΘΗΜΑ: Προγραμματιστικά Εργαλεία και Τεχνολογίες για Επιστήμη Δεδομένων

ΔΙΔΑΣΚΩΝ: Δημήτρης Φουσκάκης

ΑΚΑΔΗΜΑΙΚΟ ΕΤΟΣ: 2019-2020

Εργαστηριακή Άσκηση στην R

21/2/2020

Τίτλος: Προγραμματισμός με Χρήση της R

Άσκηση 1η: Η συνάρτηση μάζας πιθανότητας της κατανομής Poisson είναι η

$$P(X = x) = \frac{e^{-\lambda} \lambda^x}{x!}, x = 0, 1, \dots, \lambda > 0.$$

Επειδή όμως χρειάζεται να υπολογιστεί το παραγοντικό στον παρονομαστή, ο παραπάνω ορισμός δεν είναι ιδιαίτερα εύχρηστος. Για αυτό το λόγο στην πράξη χρησιμοποιούμε αναδρομικό τύπο και συγκεκριμένα, υπολογίζουμε την $P(X = 0) = e^{-\lambda}$ και στη συνέχεια οι υπόλοιπες πιθανότητες προκύπτουν ως

$$P(X = x) = P(X = x - 1) \frac{\lambda}{x}, x = 1, 2, \dots$$

Να γράψετε μια συνάρτηση στην R που να έχει ως παραμέτρους εισόδου την τιμή της παραμέτρου λ και την τιμή x για την οποία θέλετε να υπολογίσετε την πιθανότητα και η οποία να επιστρέφει ως αποτέλεσμα την συνάρτηση μάζας πιθανότητας της κατανομής Poisson στο σημείο x . Αν η τιμή εισόδου x δεν είναι φυσικός αριθμός καθώς και αν η τιμή εισόδου λ δεν είναι μεγαλύτερη του μηδενός η συνάρτησή σας θα πρέπει να επιστρέφει ένα μήνυμα λάθους.

Άσκηση 2η: Α) Να γράψετε μια συνάρτηση στην R η οποία να παίρνει ως παράμετρο εισόδου ένα διάνυσμα δεδομένων \mathbf{X} (διάστασης n) και κατόπιν να υπολογίζει την ποσότητα

$$G = \frac{2}{n(n-1)} \sum_{i=1}^n (2i - n - 1) X_{(i)},$$

όπου $X_{(i)}$ είναι η i διατεταγμένη (κατά αύξουσα τάξη μεγέθους) συνιστώσα του διανύσματος \mathbf{X} . Η συνάρτηση θα πρέπει να επιστρέφει τόσο την τιμή του G , όσο και τη διάσταση του διανύσματος \mathbf{X} .

Β) Έστω η τ.μ. $X \sim \text{Βήτα}(4,5)$. Με ποιες εντολές της R θα υπολογίζατε:

- i) Την πιθανότητα $P(X \leq 0.5)$.
- ii) Την τιμή α για την οποία $P(X > \alpha) = 0.2$.
- iii) Την τιμή της σ.π.π. της τ.μ. X στο σημείο 0.2.

Άσκηση 3η: Το *bootstrap* είναι μια μέθοδος επαναδειγματοληψίας ιδιαίτερα χρήσιμη για την εκτίμηση του τυπικού σφάλματος ενός εκτιμητή $\hat{\theta}$. Θεωρούμε ότι έχουμε ένα τυχαίο δείγμα αποτελούμενο από N παρατηρήσεις $\mathbf{y} = (y_1, \dots, y_N)^T$ και επαναλαμβάνουμε B φορές τα παρακάτω βήματα:

- i. Δημιουργούμε ένα *bootstrap* δείγμα μεγέθους N , με δειγματοληψία με επανάθεση από το αρχικό δείγμα.
- ii. Υπολογίζουμε την τιμή του εκτιμητή στο *bootstrap* δείγμα που δημιουργήσαμε. Μετά το πέρας της επαναληπτικής αυτής διαδικασίας, έχουμε αποθηκεύσει ένα σύνολο εκτιμητών *bootstrap* $\hat{\theta}_{(boot)} = (\hat{\theta}_{(1)}, \dots, \hat{\theta}_{(B)})^T$. Τέλος, υπολογίζουμε το τυπικό σφάλμα *bootstrap* του εκτιμητή $\hat{\theta}$ από τον τύπο:

$$se(\hat{\theta}_{(boot)}) = \left[\frac{1}{B-1} \sum_{i=1}^B (\hat{\theta}_{(i)} - \bar{\hat{\theta}})^2 \right]^{1/2},$$

όπου $\bar{\hat{\theta}}$ η μέση τιμή των εκτιμητών *bootstrap*, δηλαδή $\bar{\hat{\theta}} = B^{-1} \sum_{i=1}^B \hat{\theta}_{(i)}$.

Να γραφτεί μια συνάρτηση στην R που να υλοποιεί τον αλγόριθμο *bootstrap* αν θεωρήσουμε ότι ο εκτιμητής ενδιαφέροντος είναι ο δειγματικός συντελεστής μεταβλητότητας ($CV = 100 \cdot (s/|\bar{y}|)\%$, όπου s είναι η δειγματική τυπική απόκλιση και \bar{y} ο δειγματικός μέσος), με βάση ένα διάνυσμα παρατηρήσεων \mathbf{y} που θα δίνει ο χρήστης σαν παράμετρο εισόδου καθώς και τον αριθμό B . Η συνάρτηση θα πρέπει να επιστρέφει σε μια λίστα με κατάλληλα ονόματα την τιμή του τυπικού σφάλματος *bootstrap* καθώς και τις τιμές των εκτιμητών *bootstrap*.