

Εργασία 4

Δίνεται αρχείο στην R, διαθέσιμο στις εργασίες - ηλεκτρονική με τα δεδομένα φοιτητών του χειμερινού εξαμήνου 2017, που αγοράζουν τη βαρμολογία τους την πρώτη φορά που έδωσαν πιθανότητες **I**.

(i) ανοίξτε το αρχείο με την R (αφού πρώτα κάνετε εγκατάσταση του λογισμικού). Θα παρατηρήσετε ότι δίνονται 2 σύνολα δεδομένων. Το πρώτο αφορά σποριακά τα δεδομένα και το δεύτερο μόνο για τα ~~κρίσιμα~~ **κρίσιμα**. Μπορείτε να χρησιμοποιήσετε όποιο λογισμικό θέλετε για να αναλύσετε τα δεδομένα.

Υπολογίστε το \bar{x} και το s^2 . Κάντε το ισόγραμμα των σχετικών συχνοτήτων για να έχετε μια ιδέα για τη μορφή της κατανομής των βαρών των φοιτητών. Σχολιάστε.

(ii) Υποθέστε τώρα ότι το δείγμα αυτό, προέρχεται από $\text{Bin}(10, p)$. Εκτιμήστε το p με τη μέθοδο των ροπών, και συγκρίνετε το λόγο $\frac{s^2}{\bar{x}}$ με τον αντίστοιχο θεωρητικό. Σχολιάστε τα αποτελέσματα. Διηρημίστε πάνω στο ισόγραμμα σχετ. συχνοτήτων.

(iii) Αρχίστε να σκέφτεστε πιο ρεαλιστικά μοντέλα. Χωρίστε πρώτα τους φοιτητές σε αδιάβαστους (A) και διαβασμένους (Δ). Υποθέστε ότι οι A γράφουν βαθμούς από 0-2, ενώ οι διαβασμένοι από 3-10. Υποθέστε ότι ένας A, γράφει βαθμό $X \sim \text{Bin}(2, p_a)$, ενώ ένας διαβασμένος, γράφει βαθμό $Y \sim \text{Bin}(3, p_b) + \text{Bin}(7, p_b)$. Εκτιμώντας το ποσοστό των διαβασμένων με

$$\pi = \frac{\# \text{φοιτητών με βαθμό} \geq 3}{\# \text{όλων των φοιτητών}}, \text{ εκτιμήστε τα } p_a \text{ και } p_b \text{ επίσης}$$

με τη μέθοδο των ροπών. Χρησιμοποιήστε τη μέθοδο μέγιστης πιθανοφάνειας, για να εκτιμήσετε τα π, p_a και p_b , αν και τα 3 είναι άγνωστα. Θεωρούμε ότι ο βαθμός

$$Z_i = \begin{cases} X_i & \text{με πιο } 1-\pi \\ Y_i & \text{με πιο } \pi \end{cases} \text{ Συγκρίνετε τα αποτελέσματα.}$$

(iv) Έχετε την πληροφορία από έναν καθηγητή, ότι κάποιοι φοιτητές που γράφουν από 3.5 - 4.0 βαθμοποιούνται με 3 και όχι με 4.

Για να ενσωματώσετε αυτήν την πληροφορία στη μοντελοποίηση σκεψτείτε 2 διαφορετικούς τρόπους:

$$(a) Z_i = \begin{cases} X_i \sim \text{Bin}(2, p_a), & \text{με πιθαν. } 1 - \pi_1 - \pi_2 \\ 3 & , \text{ με πιθαν. } \pi_2 \\ Y_i \sim 4 + \text{Bin}(6, p_b), & \text{με πιθαν. } \pi_1 \end{cases}$$

$$(b) Z_i = \begin{cases} X_i \sim \text{Bin}(3, p_a), & \text{με πιθαν. } 1 - \pi_1 - \pi_2 \\ 3 & , \text{ με πιθαν. } \pi_2 \\ Y_i \sim 3 + \text{Bin}(7, p_b) & \text{με πιθαν. } \pi_1. \end{cases}$$

Τα μοντέλα αυτά έχουν πλέον 4 παραμέτρους υπό εκτίμηση. Εκτιμήστε με τη μέθοδο μέγιστης πιθανοφάνειας (ενδεχομένως με αλγόριθμο) για κάποιο από αυτά

Τα (α) και (β).

(v) Προτείνετε και εσείς ένα μοντέλο, και εκτιμήστε τις παραμέτρους του με τη μέθοδο μέγιστης πιθανοφάνειας.

(vi) Συγκρίνετε όλα τα μοντέλα που προτάθηκαν με το κριτήριο $AIC(m) = -2 \log L(\hat{\theta}) + 2k$ και καταλήξτε στο καλύτερο μοντέλο που περιγράφει τα δεδομένα σε αυτά τα πραγματικά δεδομένα (γραφήματα επίσης) # παραμέτρους υπό εκτίμηση

Παρατήρηση: * Για το (v) μπορείτε να προτείνεται όποιο μοντέλο θέλετε, αρκεί να είτασε σε θέση να εκτιμήσετε τις παραμέτρους του, με την ε.μ.π. (αναγκαστικά ή με αλγόριθμο)

* Σε σχέση με το (iv) μην ξεχνάτε επίσης ότι πολλοί φοιτητές που γράφουν από 4.0 - 4.5 βαθμοποιούνται επίσης με 5

↓
(μπορεί και μικρότερο)