

MEM-205 Περιγραφική Στατιστική
Τμήμα Μαθηματικών και Εφ. Μαθηματικών, Πανεπιστήμιο Κρήτης

Κώστας Σμαραγδάκης (kesmarag@gmail.com)

06-03-2023

Αριθμός συνδυασμών

Ο αριθμός των δυνατών συνδυασμών της επιλογής K διακεκριμένων στοιχείων από N συνολικά στοιχεία συμβολίζεται ως ${}_N C_K$ και δίνεται από τη σχέση:

$${}_N C_K = \binom{N}{K} = \frac{N!}{(N - K)!K!}$$

Παράδειγμα

Μια τράπεζα θέλει να προσλάβει 3 νέους ταμίες. Υπάρχουν για τις θέσεις 10 ισάξιοι υποψήφιοι οπότε επιλέγονται 3 στην τύχη. Πόσοι διαφορετικοί συνδυασμοί υπάρχουν;

$${}_{10} C_3 = \binom{10}{3} = \frac{10!}{(10 - 3)!3!} = 120$$

Αριθμός διατάξεων

Ο αριθμός των πιθανών διατάξεων για την επιλογή K διακεκριμένων στοιχείων από N συνολικά στοιχεία συμβολίζεται ως ${}_N P_K$ και δίνεται από τη σχέση:

$${}_N P_K = \frac{N!}{(N - K)!} = (N - K + 1) \cdots N$$

Παράδειγμα

Ένα κουτί περιέχει 10 αριθμημένες μπάλες (0-9). Σχηματίζουμε τριψήφιο αριθμό επιλέγοντας τυχαία 3 μπάλες (χωρίς επανατοποθέτηση). Η πρώτη μπάλα θα αντιστοιχεί στις εκατοντάδες, η δεύτερη στις δεκάδες και η τελευταία στις μονάδες. Πόσοι αριθμοί μπορούν να σχηματισθούν;

$${}_{10} P_3 = \frac{10!}{(10 - 3)!} = 10 * 9 * 8 = 720$$

\bar{X} ως Τυχαία Μεταβλητή

Δειγματική κατανομή της \bar{X}

Η στατιστική κατανομή της \bar{X} καλείται δειγματική κατανομή της \bar{X} .

Γενικά η στατιστική κατανομή οποιοδήποτε στατιστικού του δείγματος καλείτε ως δειγματική κατανομή του συγκεκριμένου στατιστικού.

Δειγματικό Σφάλμα

Είναι η διαφορά μεταξύ της τιμής ενός στατιστικού ενός δείγματος και της αντίστοιχης τιμής του στατιστικού που αφορά τον πληθυσμό. Στη περίπτωση της μέσης τιμής έχουμε:

$$\text{Δειγματικό σφάλμα} = \bar{X} - \mu$$

↑ δειγματική
↓ μέση τιμή του πληθυσμού

Δειγματικές Κατανομές (Sampling Distributions)

Παράδειγμα

$$\mu = \frac{5+3+7+10+6}{5}$$

Έστω ότι σε ένα μάθημα υπηρξαν μόνο 5 εγγεγραμμένοι φοιτητές και οι τελική τους αξιολόγηση ήταν: 5, 3, 7, 10, 6. Βρείτε τη μέση τιμή όλων των δειγμάτων με τρία στοιχεία. Στη συνέχεια υπολογίστε τη δειγματική κατανομή της \bar{X} των δειγμάτων με τρία στοιχεία.

Έχουμε συνολικά 10 δείγματα. Γιατί;

$$\binom{5}{3} = \frac{5!}{3!2!} = 4 \cdot 5 / 2 = 10$$

$$(5, 3, 7) \rightarrow \bar{X} = 5, (5, 3, 10) \rightarrow \bar{X} = 6, (5, 3, 6) \rightarrow \bar{X} = 4.67, (5, 7, 10) \rightarrow \bar{X} = 7.33, (5, 7, 6) \rightarrow \bar{X} = 6$$

$$(5, 10, 6) \rightarrow \bar{X} = 7, (3, 7, 10) \rightarrow \bar{X} = 6.67, (3, 7, 6) \rightarrow \bar{X} = 5.33, (3, 10, 6) \rightarrow \bar{X} = 6.33, (7, 10, 6) \rightarrow \bar{X} = 7.67$$

$\{5, 6, 4.67, \dots, 7.67\}$

$$E[\bar{X}_3] = \frac{5+6+\dots+7.67}{10} = \mu_{\bar{X}_3} =$$

$$\bar{X}_3 \quad \text{Var}[\bar{X}_3] = E[\bar{X}_3^2] - (E[\bar{X}_3])^2 = \sigma_{\bar{X}_3}^2$$

- ▶ Η μέση τιμή της δειγματικής κατανομής της \bar{X} συμβολίζεται ως $\mu_{\bar{X}}$
- ▶ Η τυπική απόκλιση της δειγματικής κατανομής της \bar{X} συμβολίζεται ως $\sigma_{\bar{X}}$

$(\mu_{\bar{X}} = \mu)$ εαν ο πληθυσμός είναι πεπερασμένος.

Όταν το δείγμα είναι μικρό συγκριτικά με το πληθυσμό ($N/N_p \leq 0.05$)

$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{N}}$$

↑ ↑ Πλήθος των στοιχείων του πληθυσμού.
δειγματος.

Όταν η παραπάνω συνθήκη δεν ικανοποιείται χρησιμοποιούμε την έκφραση:


$$\sigma_{\bar{X}} = \sqrt{\frac{N_p - N}{N_p - 1} \frac{\sigma}{\sqrt{N}}}$$

Δειγματοληψία από Πληθυσμό που ακολουθεί Κανονική κατανομή

$$X \sim N(\mu, \sigma^2) \quad \bar{X}_N \sim N\left(\mu, \frac{\sigma^2}{N}\right)$$

$$X \sim N(0, 1) \quad \bar{X}_3 \sim N\left(0, \frac{1}{3}\right)$$


Εάν X ακολουθεί την $\mathcal{N}(\mu, \sigma^2)$ τότε η \bar{X} ακολουθεί την $\mathcal{N}(\mu_{\bar{X}}, \sigma_{\bar{X}}^2)$



Δειγματοληψία από Πληθυσμό που δεν ακολουθεί Κανονική κατανομή

Σύμφωνα με το **κεντρικό οριακό θεώρημα**, για μεγάλο μέγεθος του δείγματος, η δειγματική κατανομή της \bar{X} προσεγγίζει τη κανονική κατανομή $(\mu_{\bar{X}}, \sigma_{\bar{X}}^2)$ ανεξάρτητα της κατανομής που ακολουθεί η X .

Σε αυτή τη περίπτωση θεωρούμε ένα δείγμα επαρκώς μεγάλο όταν $N \geq 30$.



$$\begin{array}{ll}
 X \sim N(\mu, \sigma^2) & P[\bar{X}_N \in [a, b]] \\
 X \not\sim N & P[\bar{X}_N \in [a, b]], \quad N \geq 30
 \end{array}$$

1. Για X που ακολουθεί κανονική κατανομή, υπολογισμός της πιθανότητας η \bar{X} να ανήκει σε συγκεκριμένο διάστημα.
2. Για X που δεν ακολουθεί κανονική κατανομή, υπολογισμός της πιθανότητας η \bar{X} να ανήκει σε συγκεκριμένο διάστημα όταν $N \geq 30$.

Σε κάθε περίπτωση μπορούμε να υπολογίσουμε το **z-score** για την \bar{X}

$$z = \frac{\bar{X} - \mu}{\sigma_{\bar{X}}} \quad \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{N}}$$

$$z = \sqrt{N} \frac{\bar{X} - \mu}{\sigma}$$

Εφαρμογές Δειγματικής Κατανομής της \bar{X}

Ο χρόνος παράδοσης παραγγελιών σε ένα fast food στις ώρες αιχμής ακολουθεί κανονική κατανομή με μέση τιμή 8.4 λεπτά και τυπική απόκλιση 1.8 λεπτά. Για ένα τυχαίο δείγμα 16 παραγγελιών υπολογίστε την πιθανότητα η μέση τιμή του δείγματος να είναι:

1. Μεταξύ 8 και 9 λεπτών.
2. Τουλάχιστον 1 λεπτό λιγότερο από τη μέσο χρόνο παράδοσης που αντιστοιχεί σε όλο τον πληθυσμό.

$$P[\bar{X}_{16} \in [\overset{z_1}{\underset{\downarrow}{8}}, \overset{z_2}{\underset{\downarrow}{9}}]] = ;$$

$$\mu = 8.4 \quad \sigma = 1.8$$

$$\bar{X}_{16} \sim N(8.4, \frac{1.8^2}{16})$$

$$Z = \frac{\bar{X} - \mu_{\bar{X}}}{\sigma_{\bar{X}}} = \sqrt{16} \frac{\bar{X} - 8.4}{1.8} =$$

$$z_1 = 4 \frac{8 - 8.4}{1.8} = 4 \cdot \frac{-0.4}{1.8} = -\frac{8}{9}$$

$$z_2 = 4 \frac{9 - 8.4}{1.8} = 4 \frac{0.6}{1.8} = \frac{4}{3}$$



Εφαρμογές Δειγματικής Κατανομής της \bar{X}


Ο χρόνος παράδοσης παραγγελιών σε ένα fast food στις ώρες αιχμής ακολουθεί κανονική κατανομή με μέση τιμή 8.4 λεπτά και τυπική απόκλιση 1.8 λεπτά. Για ένα τυχαίο δείγμα 16 παραγγελιών υπολογίστε την πιθανότητα η μέση τιμή του δείγματος να είναι:

1. Μεταξύ 8 και 9 λεπτών.
2. Τουλάχιστον 1 λεπτό λιγότερο από τη μέσο χρόνο παράδοσης που αντιστοιχεί σε όλο τον πληθυσμό.

Στ. νοση. $cdf(z)$



2.



$$P(\bar{X} \geq 7.4) = 1 - P(Z \leq z_3)$$

$$z_3 = \frac{7.4 - 8.4}{1.8} \cdot 4 = \frac{-4}{1.8}$$

Μια αναλογία στο πληθυσμό προκύπτει ως το λόγο του αριθμού των στοιχείων του πληθυσμού που παρουσιάζουν μια χαρακτηριστική ιδιότητα με το μέγεθος του πληθυσμού. Συμβολίζεται με p . Η αντίστοιχη αναλογία για ένα δείγμα συμβολίζεται με \hat{p} .

$$p = \frac{M_p}{N_p}, \quad \hat{p} = \frac{M}{N}$$

$$\hat{p} \xrightarrow{N \rightarrow N_p} p$$

Όπου:

- ▶ N_p το μέγεθος του πληθυσμού.
- ▶ M_p αριθμός στοιχείων του πληθυσμού που παρουσιάζουν την ιδιότητα που μελετάμε.
- ▶ N το μέγεθος του δείγματος.
- ▶ M αριθμός στοιχείων του δείγματος που παρουσιάζουν την ιδιότητα που μελετάμε.

Μέση Τιμή και Τυπική Απόκλιση του \hat{p}

- ▶ Η μέση τιμή της δειγματικής κατανομής της \hat{p} συμβολίζεται ως $\mu_{\hat{p}}$
- ▶ Η ~~μέση τιμή~~ ^{τυπική απόκλιση.} της δειγματικής κατανομής της \hat{p} συμβολίζεται ως $\sigma_{\hat{p}}$

$$\mu_{\hat{p}} = p$$

Όταν το δείγμα είναι μικρό συγκριτικά με το πληθυσμό ($N/N_p \leq 0.05$)

$$\sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{N}}$$

Όταν η παραπάνω συνθήκη δεν ικανοποιείται χρησιμοποιούμε την έκφραση:

$$\sigma_{\hat{p}} = \sqrt{\frac{N_p - N}{N_p - 1}} \sqrt{\frac{p(1-p)}{N}}$$

Από το κεντρικό οριακό θεώρημα όταν N_p και $N(1-p)$ αρκετά μεγάλοι αριθμοί η \hat{p} ακολουθεί την κατανομή $\mathcal{N}(\mu_{\hat{p}}, \sigma_{\hat{p}}^2)$. Σε αυτή τη περίπτωση θεωρούμε ότι επαρκεί $N_p > 5$ και $N(1-p) > 5$

$$P(\hat{p} \in [a, b]) = ;$$

1. Υπολογισμός της πιθανότητας το \hat{p} να είναι μικρότερο από μια συγκεκριμένη τιμή.
2. Υπολογισμός της πιθανότητας το \hat{p} να ανοίκει σε ένα διάστημα.

Το **z-score** για τη δειγματική κατανομή της \hat{p} δίνεται ως:

$$Np > 5 \text{ και } N(1-p) > 5$$

$$z = \frac{\hat{p} - p}{\sigma_{\hat{p}}} \quad \sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{N}}$$

$$\hat{p} \sim N\left(p, \frac{p(1-p)}{N}\right)$$

$$\min(Np, N(1-p)) > 5$$

Παράδειγμα

Ένας υποψήφιος δήμαρχος μιας μεγάλης πόλης ισχυρίζεται ότι έχει τη στήριξη του 53 % των ψηφοφόρων. Εάν δεχτούμε τον ισχυρισμό του ως αλήθινο ποιά είναι η πιθανότητα σε ένα τυχαίο δείγμα 400 ψηφοφόρων λιγότεροι από 49 % να στηρίζουν τον υποψήφιο;

$$p = 0.53$$

$$N = 400$$

$$\hat{p} = 0.49$$

$$z_1 = \frac{\hat{p} - p}{\sigma_{\hat{p}}}$$

$$\sigma_{\hat{p}} = \sqrt{\frac{0.53 \cdot 0.47}{400}}$$

$$\boxed{\begin{matrix} Np > 5 \\ N(1-p) > 5 \end{matrix}}$$

$$z_1 = \frac{0.49 - 0.53}{\sqrt{\frac{0.53 \cdot 0.47}{400}}} = -\frac{0.04}{0.02445} = -1.602$$

$$P[Z \leq z_1] = 0.054$$

- ▶ Όταν δεν γνωρίζουμε τη τιμή του p δεν μπορούμε να υπολογίσουμε το $\sigma_{\hat{p}}$

Εκτιμητήρια της τυπικής απόκλισης της \hat{p} για μεγάλο δείγμα

$$s_{\hat{p}} = \sqrt{\frac{\hat{p}(1 - \hat{p})}{N}}$$


$$\sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{N}}$$

Διάστημα εμπιστοσύνης της p

Το $(1 - \alpha) * 100\%$ διάστημα εμπιστοσύνης για την αναλογία p στο πληθυσμό είναι:

$$95\% \quad \alpha = 0.05 \quad [\hat{p} - z s_{\hat{p}}, \hat{p} + z s_{\hat{p}}],$$

όπου z το z-score για το οποίο $P(Z < \frac{z}{\sqrt{2}}) = 1 - \alpha/2$.



Τότε

$$P(p \in [\hat{p} - z s_{\hat{p}}, \hat{p} + z s_{\hat{p}}]) = 1 - \alpha$$

Παράδειγμα

Σε δείγμα 1000 ατομών μιας χώρας το 30% μετρήθηκε να έχει ηλικία μικρότερη από 25 έτη. Βρείτε το 99% διάστημα εμπιστοσύνης για το ποσοστό του πληθυσμού της χώρας με ηλικία μικρότερη από 25 έτη.

$$N = 1000$$

$$\hat{p} = 0.3$$

$$\alpha = 0.01$$

$$P(Z \leq z) = 0.995$$

← από τον πίνακα πρέπει να βρω το z.

$$S_{\hat{p}} = \sqrt{\frac{0.3 \cdot 0.7}{1000}}$$

$$p \in [0.3 - z S_{\hat{p}}, 0.3 + z S_{\hat{p}}] \quad \text{με πιθανότητα } 0.99$$

