

↳ Σκοπός Στατιστικής: Χρησιμοποιώντας βιολογικά δεδομένα y_1, \dots, y_n να εξαχθούν συμπεράσματα για έναν ολόκληρο πληθυσμό.

Παρατηρητική
Στατιστική

Μη Παρατηρητική
Στατιστική

→ 1^ο Βήμα: Υπόθεση για την κατανομή (τυχαίος μηχανισμός) που "γέννησε" τα δεδομένα που παρατηρούμε στο δείγμα που εξετάζουμε.

2^ο Βήμα: Για την κατανομή του 1^{ου} βήματος εκτίμηση των παραμέτρων της έτσι ώστε η συγκεκριμένη κατανομή (με τις συγκεκριμένες) τιμές παραμέτρων να ταιριάζει όσο το δυνατόν περισσότερο με τα δεδομένα που μελετάμε.

• Για την εκτέλεση του 1^{ου} βήματος απαιτείται η γνώση κάποιων κοινών χρησιμοποιούμενων κατανομών
• Παρακάτω παρατίθενται για λίγα με τις πιο κοινές κατανομές (συνεχείς κ' διακριτές)

Διακριτές Κατανομές

(2)

1) Διακριτή Ομοιόμορφη Κατανομή: Χρησιμοποιείται όταν
Περίπτωση πεπερασμένου δειγματικού χώρου και
όταν όλα τα πιθανά ευδεχόμενα συμβαίνουν με
την ίδια πιθανότητα.

↳ Ορισμός: Για κάθε $x \in \{1, \dots, N\}$

$$f(x) = P(X=x) = \frac{1}{N}$$

$$E(X) = \frac{N+1}{2}, \quad \text{Var } X = \frac{(N+1)(N-1)}{12}$$

Άσκηση: Ν.δ.ο. η $f(x)$ είναι συνάρτηση πιθανότητας
κ' να αποδείξετε τους τύπους για $E(X)$ κ' $\text{Var } X$.

Λύση

$$\text{Έχουμε ότι } \sum_x f(x) = \sum_{x=1}^N \frac{1}{N} = \underbrace{\frac{1}{N} + \frac{1}{N} + \dots + \frac{1}{N}}_{N \text{ φορές}} =$$

$$= N \cdot \frac{1}{N} = 1 \quad \text{κ' (ii) } f(x) \geq 0 \quad \forall x$$

άρα η $f(x)$ είναι συνάρτηση πιθανότητας

$$\begin{aligned} E(X) &= \sum_x x f(x) = \sum_{x=1}^N x \frac{1}{N} = 1 \cdot \frac{1}{N} + 2 \cdot \frac{1}{N} + \dots + N \cdot \frac{1}{N} = \\ &= \frac{1+2+\dots+N}{N} = \frac{N(N+1)}{2} = \\ &= \frac{N+1}{2} \end{aligned}$$

$$\text{Var } X = EX^2 - (EX)^2 = EX^2 - \frac{(N+1)^2}{4} \quad (3)$$

$$EX^2 = \sum_x x^2 f(x) = \sum_{x=1}^N x^2 \frac{1}{N} = \frac{1}{N} \sum_{x=1}^N x^2 = \frac{1}{N} \frac{N(N+1)(2N+1)}{6}$$

$$\begin{aligned} \text{Ότι} \quad EX^2 - (EX)^2 &= \frac{(N+1)(2N+1)}{6} - \frac{(N+1)^2}{4} = \\ &= \frac{(2N+2)(2N+1) - 3(N+1)^2}{12} = \\ &= \frac{4N^2 + 2N + 2 - 3N^2 - 6N - 3}{12} \end{aligned}$$

$$= \frac{N^2 - 4N - 1}{12} = \frac{(N-1)(N+1)}{12}$$

2) Bernoulli Κατανομή: Χρησιμοποιείται όταν το υπό μελέτη πείραμα έχει μόνο 2 πιθανές αποτελέσματα (Επιτυχία/Αποτυχία) και η πιθανότητα επιτυχίας είναι ίση με p . Συμβολικά γράφεται

$$X \sim \text{Bernoulli}(p)$$

Για $x \in \{0, 1\}$

$$f(x) = P(X=x) = \overset{\text{Παράδειγμα της κατανομής}}{p}^x (1-p)^{1-x}$$

$$E(X) = p \quad \text{Var } X = p(1-p)$$

Παραδείγματα: i) Ριψη νοτίσματος (κασίλλης)
ii) Το αποτέλεσμα της προοπτικής ενός πωλητή να πουλήσει ένα προϊόν

3) Δωροτυπική Κατανομή : Χρησιμοποιείται όταν έχεις ⁽⁴⁾
 \implies η ανεξάρτητες επαναλήψεις ενός πειράματος με 2 πιθανά αποτελ. και σε
κάθε επανάληψη η πιθαν. επιτυχίας είναι p

$$X \sim \text{Bin}(n, p)$$

Παράμετροι
της κατανομής

• Για $x \in \{0, 1, \dots, n\}$

$$\begin{aligned} f(x) = P(X=x) &= \binom{n}{x} p^x (1-p)^{n-x} = \\ &= \frac{n!}{(n-x)! x!} p^x (1-p)^{n-x} \end{aligned}$$

$$EX = np, \quad \text{Var } X = np(1-p)$$

Ιδιότητες

• Για $n=1$ η Bernoulli(p) είναι ειδική περίπτωση της Binomial(n, p).

• Εάν $X \sim \text{Bin}(n, p)$ κ' $Y \sim \text{Bin}(m, p)$

$$\text{τότε } X+Y \sim \text{Bin}(n+m, p)$$

Παράδειγμα: Ένα προϊόν βιομηχανικής παραγωγής (5)

μπορεί να είναι ελαττωματικό με πιθανότητα 0.005

α) Ποια η πιθανότητα να έχουμε ένα ^{αποτέλεσμα} ελατ. σε δείγμα ~~με~~ μεγέθους 15?

β) Εάν κάθε ώρα παράγονται 1000 προϊόντα πόσα αναμένεται να είναι ελαττωματικά

Λύση

α) Έστω X η τ.φ. που "λείπει" τον αριθμό των ελαττωματικών σε 15 προσπάθειες

$$\text{Βία } X \sim \text{Bin}(15, 0.005)$$

$$P(X \geq 1) = 1 - P(X=0) =$$

$$1 - \binom{15}{0} p^0 (1-p)^{15-0} =$$
$$1 - \frac{15!}{(15-0)!0!} 0.005^0 \cdot 0.995^{15} = 1 - 0.995^{15} =$$

$$= 0.072 = 7,2\%$$

β) ~~Πολλοί ελαττωματικοί~~

$$X \sim \text{Bin}(1000, 0.005)$$

$$EX = 1000 \cdot 0.005 = 5$$

4) Poisson κατανομή: Χρησιμοποιείται για να "μετρήσουμε" τον αριθμό γεγονότων σε μια χρονική περίοδο.

$$X \sim \text{Pois}(\lambda)$$

Για $X \in \{0, 1, 2, \dots\}$, $f(x) = \frac{e^{-\lambda} \lambda^x}{x!}$

$$EX = \text{Var}X = \lambda$$

Ιδιότητες:

• Αν $X_i \sim \text{Pois}(\lambda_i)$, $i=1, \dots, n$ και X_i ανεξ. τ.μ.

$$\text{τότε } \sum_{i=1}^n X_i \sim \text{Pois}(\sum_{i=1}^n \lambda_i)$$

Παράδειγμα: Ο αριθμός των μ θυγατρικών τροχαίων ανά εβδομάδα ακολουθεί την Poisson κατανομή με μέσο λ .

α) Ποια η πιθαν. να έχουμε τουλάχιστον ένα στίγμα κάποια εβδομάδα

β) Ποια η πιθαν. κάτι σε ένα μήνα να συμβούν δυσχήματα

Λύση

$$\begin{aligned} \alpha) X &\sim \text{Pois}(\lambda) & P(X \geq 1) &= 1 - P(X=0) \\ & & &= 1 - e^{-\lambda} \frac{\lambda^0}{0!} = 1 - \frac{1}{e} \\ & & &= 0.632 = 63,2\% \end{aligned}$$

8) Από την εβδομάδα έχεις κατά μέσο όρο 1 ατύχημα, το μίνα θα έχεις κατά μέσο όρο 4 ατυχήματα.

Αρα αν X ο αριθμός μ θανατηφόρων ατυχημάτων σε ~~ένα~~ ^{ένα} μήνα τότε

$$X \sim \text{Pois}(4)$$

$$\text{αρα } P(X=0) = e^{-4} \frac{4^0}{0!} = \frac{1}{e^4} = 0,018 = 1,8\%$$

* Άλλες κοινές διακριτές κατανομές:

- 4 Αρνητική Διωνυμική
- 4 Γεωμετρική
- 4 Υπεργεωμετρική
- ...

→ Συνεχείς Κατανομές:

1) ~~Οποιαδήποτε~~ Οποιαδήποτε κατανομή στο διάστημα (a, b)

$$\text{Για } x \in (a, b) \text{ έχουμε } f(x) = \frac{1}{b-a}$$

$$E X = \frac{b+a}{2}, \quad \text{Var } X = \frac{(b-a)^2}{12}$$

Παράδειγμα: Έστω ότι επισκεπτόμαστε μια πόλη στο εξωτερικό και φτάουμε στον σταθμό τρένων. Ξέρουμε μόνο ότι τρένο για τον προορισμό μας περνάει κάθε 45 λεπτά αλλά όχι την ακριβή ώρα

α) Ποια η πιθαν. να περιέχουμε το ποσό 10 λεπτά? (8)

β) Ποιος ο αναμενόμενος χρόνος μέχρι την πρώτη αναχώρηση

Λύση

Έστω X ο χρόνος σε λεπτά ανάμεσα σε 2 τρένα

Γιλέ $X \sim U(0, 45)$

$$\alpha) P(X \leq 10) = \int_0^{10} \frac{1}{45} dx = \frac{x}{45} \Big|_0^{10} = \frac{10}{45} = 0,22 = 22\%$$

$$\beta) EX = \frac{0+45}{2} = 22,5 \text{ λεπτά}$$

2) Κανονική κατανομή (Normal or Gaussian distribution)

$$X \sim N(\mu, \sigma^2)$$

παραμέτρους

Η πιο συχνά χρησιμοποιούμενη κατανομή στην στατιστική και την Οικονομική

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

$$EX = \mu, \text{ Var } X = \sigma^2$$

Παράδειγμα : Μια εταιρεία παράγει βερδικούς
 αβζόνες των οποίων το μήκος
 ακολουθεί την κανονική κατανομή
 με μέση τιμή $0,2508\text{cm}$ και τυπική
 απόκλιση $0,0015\text{cm}$. Για να είναι
 αποδεκτός στην αγορά ο αβζόνας
 πρέπει να έχει μήκος
 $0,250 \pm 0,0015\text{cm}$

- α) Ποιο το ποσοστό των παραχθέντων αβζόνων πληροί τις προδιαγραφές;
- β) Αν μπορούσατε να διαπραγματευτείτε την γραμμή παραγωγής σε ποιο κόστος θα πρέπει να στοχεύατε για να ελαχιστοποιηθούν οι παραχθέντες μη αποδεκτοί αβζόνες.

Λύση


α) $X \sim N(\mu = 0,2508, \sigma^2 = 0.0015^2)$

$P(0.2485 < X < 0.2515) =$

$$= P(X < 0.2515) - P(X < 0.2485) =$$

$$= \int_{-\infty}^{0.2515} \frac{1}{0.0015\sqrt{2\pi}} e^{-\frac{1}{2 \cdot 0.0015^2} (x - 0,2508)^2} dx -$$

$$- \int_{-\infty}^{0.2485} \dots = \Phi(0.2515) - \Phi(0.2485)$$



Ιδιότητες:

(10)

- Αν $\mu=0$ και $\sigma=1$ τότε η κατανομή λέγεται τυπική κανονική κατανομή και συμβολίζεται

$$\text{ως } Z \sim N(0, 1)$$

Ισχύει ότι: i) Αν $X \sim N(\mu, \sigma^2)$

$$\text{τότε } \frac{X-\mu}{\sigma} \sim N(0, 1)$$

ii) Αν $Z \sim N(0, 1)$ τότε

$$X = \sigma Z + \mu \sim N(\mu, \sigma^2)$$

- Ο κανόνας των τριών τυπικών αποκλίσεων

$$i) P(|X-\mu| \leq \sigma) = 0,6826 = 68,26\%$$

$$ii) P(|X-\mu| \leq 2\sigma) = 0,9544 = 95,44\%$$

$$iii) P(|X-\mu| \leq 3\sigma) = 0,9973 = 99,73\%$$

Π.χ. αν $X \sim N(\mu=15, \sigma^2=4)$

$$\text{τότε } \sigma = \sqrt{4} = 2$$

και οι τιμές της $\mu \pm 99\%$ πιθαν. ανήκουν

στο ~~επίπεδο~~ διάστημα $(9, 21)$

• Αν X_1, X_2 ανεξάρτητες κανονικές λ.κ. με
μέσες τιμές μ_1, μ_2 και διασπορές σ_1^2, σ_2^2 τότε

$$X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$$

• Αν $X_i, i=1, \dots, n$ ανεξάρτητες τυπικές κανονικές
(δηλ $X_i \sim N(0, 1)$)

$$\text{Τότε } Y = \sum_{i=1}^n X_i^2 = \chi_n^2$$

• Αν $X_i \sim N(\mu, \sigma^2), i=1, \dots, n$, ανεξάρτητες τότε

$$t = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1} \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

• Αν $X_i, i=1, \dots, n \sim N(0, 1)$ και $Y_j, j=1, \dots, m \sim N(0, 1)$,
ανεξάρτητες τότε

$$F = \frac{S_X^2/n}{S_Y^2/m} \sim F_{n,m}$$

~~Αν $X \sim t_\nu$ τότε $X \in (-\infty, +\infty)$~~ Αν $X \sim t_\nu$ τότε $X \in (-\infty, +\infty)$

$$\text{και } f(x) = \frac{\Gamma(\frac{\nu+1}{2})}{\Gamma(\frac{\nu}{2}) \sqrt{\nu\pi}} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

$$EX = 0, (\nu > 1) \quad \text{Var } X = \frac{\nu}{\nu-2}, \nu > 2$$

* Άλλες συνεχείς κατανομές: LogNormal
Gamma
Exponential:

(52)

~~~~~

Πολλαμεταβλητές κατανομές:

4 Διακριτό τυχόν διαυγαστο είναι το ζευγάρι  
τ.τ.  $(X, Y)$  το οποίο ταίριαξε ειδικά σε  
αριθμητικό σύνολο. Η συνάρτηση

$$f: \mathbb{R}^2 \rightarrow \mathbb{R} \text{ με}$$

$f(x, y) = P(X=x, Y=y)$  γράφεται από κοινού  
συνάρτηση πιθανότητας του  $(X, Y)$  εάν

i)  $f(x, y) \geq 0$

ii)  $\sum_x \sum_y f(x, y) = 1$

• Για  $A \subseteq \mathbb{R}^2$  έχουμε ότι

$$P((X, Y) \in A) = \sum_{(x, y) \in A} f(x, y)$$

• Από κοινού κενά είναι:

$$E(g(x, y)) = \sum_x \sum_y g(x, y) f(x, y)$$

• Περιθωπίες κατανομές

$$f_x(x) = P(X=x) = \sum_y f(x,y)$$

$$f_y(y) = P(Y=y) = \sum_x f(x,y)$$

Παράδειγμα:

|          |      |      |      |          |
|----------|------|------|------|----------|
| $f(x,y)$ | $X$  |      |      | $f_y(y)$ |
| $Y$      | 0    | 1    | 2    |          |
| 0        | 0.05 | 0.1  | 0.03 | 0.18     |
| 1        | 0.21 | 0.11 | 0.19 | 0.51     |
| 2        | 0.08 | 0.15 | 0.08 | 0.31     |
| $f_x(x)$ | 0.34 | 0.36 | 0.30 | 1.00     |

• Από κοινού κατανομή για συνεχείς τ.μ.

Αν  $(X, Y)$  συνεχείς (δισδιάστατο) τυχαίο διάνυσμα τότε

$$P((X, Y) \in A) = \iint_A f(x, y) dx dy$$

και  $f(x, y)$  αποτελείται από κοινού συνεχή συνάρτηση πιθανότητας αν

i)  $f(x, y) \geq 0$  και ii)  $\iint_{\mathbb{R}^2} f(x, y) = 1$

•  $E(g(x, y)) = \iint_{\mathbb{R}^2} g(x, y) f(x, y) dx dy$

• Περιθωπίες κατανομές  $f_x(x) = \int_y f(x, y) dy$   
 $f_y(y) = \int_x f(x, y) dx$