

Κεντρικό Οριακό Θεώρημα (Central Limit Theorem – Lindeberg Levy)

Εάν $X_i \stackrel{iid}{\sim} f(\cdot)$, $i \geq 1$ με $\mathbb{E}[X_i] = \mu$, $Var[X_i] = \sigma^2 < \infty$ και $S_n = \sum_{i=1}^n X_i$ τότε η τ.μ.

$Z_n = \frac{S_n - \mathbb{E}(S_n)}{\sqrt{Var(S_n)}} = \frac{S_n - n\mu}{\sigma\sqrt{n}}$ συγκλίνει ως προς κατανομή (converges in distribution) στη

$N(0,1)$, δηλαδή $Z_n \xrightarrow[n \rightarrow \infty]{d} N(0,1)$ ή ισοδύναμα $\lim_{n \rightarrow \infty} F_{Z_n}(x) = \lim_{n \rightarrow \infty} P\{Z_n \leq x\} = \Phi(x)$ με

$$\Phi(x) = \int_{-\infty}^x N(u|0,1) du.$$

Επειδή το Z_n αναπαρίσταται σαν $Z_n = \frac{1}{\sigma\sqrt{n}} \sum_{i=1}^n (X_i - \mu)$ πρώτα θα υπολογίσουμε την ροπογεννήτρια της τ.μ. $Y = X_i - \mu$

$$\begin{aligned} M_Y(t) &= \mathbb{E}\left[e^{t(X_i - \mu)}\right] = \mathbb{E}\left[1 + (X_i - \mu)t + \frac{1}{2}(X_i - \mu)^2 t^2 + O(t^3)\right] \\ &= 1 + \mathbb{E}(X_i - \mu)t + \frac{1}{2}\mathbb{E}\left[(X_i - \mu)^2\right]t^2 + O(t^3) = 1 + \frac{1}{2}\sigma^2 t^2 + O(t^3) \end{aligned}$$

Οπότε για την ροπογεννήτρια της Z_n θα έχουμε:

$$\begin{aligned} M_{Z_n}(t) &= \mathbb{E}\left[\exp(tZ_n)\right] = \mathbb{E}\left[\exp\left(\frac{t}{\sigma\sqrt{n}} \sum_{i=1}^n (X_i - \mu)\right)\right] = \left[M_Y\left(\frac{t}{\sigma\sqrt{n}}\right)\right]^n \\ &= \left\{1 + \frac{1}{2}\sigma^2 \left(\frac{t}{\sigma\sqrt{n}}\right)^2 + O\left(\left(\frac{t}{\sigma\sqrt{n}}\right)^3\right)\right\}^n = \left\{1 + \frac{t^2/2}{n} + O\left(\frac{t^3}{n^{3/2}}\right)\right\}^n \end{aligned}$$

$$\lim_{n \rightarrow \infty} M_{Z_n}(t) = \exp\left\{\lim_{x \rightarrow \infty} \frac{1}{x^{-1}} \log\left[1 + \frac{t^2/2}{x} + O\left(\frac{t^3}{x^{3/2}}\right)\right]\right\}$$

$$\begin{aligned} &= \exp\left\{\lim_{x \rightarrow \infty} \frac{-\frac{t^2/2}{x^2} + O\left(\frac{t^3}{x^{5/2}}\right)}{-\frac{1}{x^2}\left[1 + \frac{t^2/2}{x} + O\left(\frac{t^3}{x^{3/2}}\right)\right]}\right\} \\ &= \exp\left\{\lim_{x \rightarrow \infty} \frac{t^2/2 + O\left(\frac{t^3}{x^{1/2}}\right)}{1 + \frac{t^2/2}{x} + O\left(\frac{t^3}{x^{3/2}}\right)}\right\} = \exp\left(\frac{t^2}{2}\right). \end{aligned}$$

Δηλαδή δείξαμε ότι το όριο της ροπογεννήτριας της Z_n είναι η ροπογεννήτρια της τυπικής κανονικής. Αυτό σημαίνει ότι η τ.μ. $\lim_{n \rightarrow \infty} Z_n$ κατανέμεται σαν $N(0,1)$.

Παρατήρηση 1: Η τ.μ. Z_n είναι η τυποποίηση του δειγματικού μέσου $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$

$$Z_n = \frac{S_n - \mathbb{E}[S_n]}{\sqrt{\text{Var}[S_n]}} = \frac{S_n - n\mu}{\sigma\sqrt{n}} = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} = \frac{\bar{X}_n - \mathbb{E}[\bar{X}_n]}{\sqrt{\text{Var}[\bar{X}_n]}}$$

Παρατήρηση 2: Πρακτικά για δείγμα μεγέθους περίπου $n \geq 30$ μπορούμε να θεωρήσουμε ότι η τ.μ. Z_n βρίσκεται «πολύ κοντά» στη τυπική κανονική, δηλαδή προσεγγιστικά δεχόμαστε ότι

$$Z_n = \frac{\bar{X}_n - \mathbb{E}[\bar{X}_n]}{\sqrt{\text{Var}[\bar{X}_n]}} = \frac{\bar{X}_n - \mu}{\sqrt{\sigma^2/n}} \sim N(0,1) \Leftrightarrow \bar{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right).$$

Δηλαδή η κατανομή του δειγματικού μέσου $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ είναι προσεγγιστικά κανονική με μέσο το μ και διασπορά $\frac{\sigma^2}{n}$.

Εφαρμογή

Έχουμε δείξει ότι, εάν $X_i \stackrel{iid}{\sim} \text{Bernoulli}(p)$, $i \geq 1$ τότε $S_n \sim \text{Bin}(n, p)$, $n \geq 1$ και από το Κ.Ο.Θ. θα έχουμε

$$Z_n = \frac{S_n - \mathbb{E}[S_n]}{\sqrt{\text{Var}[S_n]}} = \frac{S_n - np}{\sqrt{np(1-p)}} \xrightarrow[n \rightarrow \infty]{d} N(0,1).$$

Εάν $n \geq 30$ προσεγγιστικά $Z_n = \frac{S_n - np}{\sqrt{np(1-p)}} \stackrel{d}{\approx} N(0,1)$ ή ισοδύναμα

$$S_n \stackrel{d}{\approx} N(np, np(1-p)).$$

Έτσι για διωνυμικές πιθανότητες με αριθμό δοκιμών $n \geq 30$ θα έχουμε για την πιθανότητα του ενδεχομένου $\{x_1 < S_n \leq x_2\}$ για $0 \leq x_1 < x_2 \leq n$, την προσέγγιση:

$$\begin{aligned} P\{x_1 < S_n \leq x_2\} &= P\left\{ \frac{x_1 - np}{\sqrt{np(1-p)}} < \frac{S_n - np}{\sqrt{np(1-p)}} \leq \frac{x_2 - np}{\sqrt{np(1-p)}} \right\} \\ &= P\left\{ \frac{x_1 - np}{\sqrt{np(1-p)}} < Z_n \leq \frac{x_2 - np}{\sqrt{np(1-p)}} \right\} \end{aligned}$$

$$= P\left\{Z_n \leq \frac{x_2 - np}{\sqrt{np(1-p)}}\right\} - P\left\{Z_n \leq \frac{x_1 - np}{\sqrt{np(1-p)}}\right\}$$

$$\approx \Phi\left(\frac{x_2 - np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{x_1 - np}{\sqrt{np(1-p)}}\right).$$

Παρατηρήστε ότι εφόσον δεχόμαστε ότι $S_n \stackrel{d}{\approx} N(np, np(1-p))$, τότε ισοδύναμα θα έχουμε:

$$P\{x_1 < S_n \leq x_2\} \approx \int_{x=x_1}^{x_2} N(x|np, np(1-p)) dx, \text{ εάν } y = \frac{x - np}{\sqrt{np(1-p)}}$$

$$P\{x_1 < S_n \leq x_2\} \approx \int_{y=\frac{x_1 - np}{\sqrt{np(1-p)}}}^{\frac{x_2 - np}{\sqrt{np(1-p)}}} N(y|1,0) dy = \Phi\left(\frac{x_2 - np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{x_1 - np}{\sqrt{np(1-p)}}\right).$$

Αριθμητική εφαρμογή

Παίκτης κερδίζει παίγνιο, με πιθανότητα $p = 0.6$. Εάν παίξει $n = 100$ ανεξάρτητα παίγνια να βρεθεί η πιθανότητα ο αριθμός των κερδισμένων παιγνίων να είναι τουλάχιστον 55 και το πολύ 70.

Θέλουμε να υπολογίσουμε την πιθανότητα του ενδεχομένου $\{54 < S_{100} \leq 70\}$.

$S_{100} \sim Bin(100, 0.6)$, με μέση τιμή $\mu = np = 60$ και τυπική απόκλιση

$\sigma = \sqrt{np(1-p)} = \sqrt{24}$. Από τα προηγούμενα έχουμε ότι:

$$P\{54 < S_{100} \leq 70\} = P\left\{\frac{54 - 60}{\sqrt{24}} < \frac{S_{100} - 60}{\sqrt{24}} \leq \frac{70 - 60}{\sqrt{24}}\right\}$$

$$= P\{-1.12 < Z_{100} \leq 2.04\}.$$

Κάνοντας την υπόθεση $Z_{100} \stackrel{d}{\approx} N(0,1)$ παίρνουμε:

$$P\{54 < S_{100} \leq 70\} \approx \Phi(2.04) - \Phi(-1.12) = \Phi(2.04) - [1 - \Phi(1.12)] \approx 0.85.$$

Εφαρμογή

Εάν $X_i \stackrel{iid}{\sim} Po(\lambda)$, $i \geq 1$, δείξτε ότι για $n \geq 30$ έχουμε τις προσεγγίσεις:

$$\sum_{x=x_1+1}^{x_2} e^{-n\lambda} \frac{(n\lambda)^x}{x!} \approx \Phi\left(\frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right) - \Phi\left(\frac{x_1 - n\lambda}{\sqrt{n\lambda}}\right), \text{ και } \sum_{x=0}^{x_2} e^{-n\lambda} \frac{(n\lambda)^x}{x!} \approx \Phi\left(\frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right)$$

Γνωρίζουμε ότι $S_n \sim Po(n\lambda)$. Από το Κ.Ο.Θ. έχουμε ότι $Z_n = \frac{S_n - n\lambda}{\sqrt{n\lambda}} \xrightarrow[n \rightarrow \infty]{d} N(0,1)$,

έτσι για $n \geq 30$ θα έχουμε $Z_n = \frac{S_n - n\lambda}{\sqrt{n\lambda}} \stackrel{d}{\approx} N(0,1)$ ή ότι $S_n \stackrel{d}{\approx} N(n\lambda, n\lambda)$ που δίνει

$$\begin{aligned} \sum_{x=x_1+1}^{x_2} e^{-n\lambda} \frac{(n\lambda)^x}{x!} &= P\{x_1 < S_n \leq x_2\} = P\left\{\frac{x_1 - n\lambda}{\sqrt{n\lambda}} < \frac{S_n - n\lambda}{\sqrt{n\lambda}} \leq \frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right\} \\ &= P\left\{\frac{x_1 - n\lambda}{\sqrt{n\lambda}} < Z_n \leq \frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right\} \approx \Phi\left(\frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right) - \Phi\left(\frac{x_1 - n\lambda}{\sqrt{n\lambda}}\right), \end{aligned}$$

ενώ

$$\begin{aligned} \sum_{x=0}^{x_2} e^{-n\lambda} \frac{(n\lambda)^x}{x!} &= P\{S_n \leq x_2\} = P\left\{\frac{S_n - n\lambda}{\sqrt{n\lambda}} \leq \frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right\} \\ &= P\left\{Z_n \leq \frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right\} \approx \Phi\left(\frac{x_2 - n\lambda}{\sqrt{n\lambda}}\right). \end{aligned}$$

Παρατήρηση

Χρησιμοποιήσαμε ότι εάν $X_i \stackrel{iid}{\sim} Bernoulli(\vartheta)$ τότε $S_n \sim Bin(n, \vartheta)$.

Η ροπογεννήτρια της Bernoulli είναι:

$$M_{X_i}(t) = M(t) = e^{t \cdot 0} P\{X_i = 0\} + e^{t \cdot 1} P\{X_i = 1\} = 1 - \vartheta + e^t \vartheta,$$

ενώ η ροπογεννήτρια της S_n

$$\begin{aligned} M_{S_n}(t) &= \mathbb{E}[e^{tS_n}] = \mathbb{E}[e^{tX_1} \dots e^{tX_n}] = \mathbb{E}[e^{tX_1}] \dots \mathbb{E}[e^{tX_n}] \\ &= M(t)^n = \{1 - \vartheta + e^t \vartheta\}^n \end{aligned}$$

Για την ροπογεννήτρια της διωνυμικής $X \sim Bin(n, \vartheta)$ έχουμε

$$\begin{aligned} M_X(t) &= \mathbb{E}[e^{tX}] = \sum_{x=0}^n e^{tx} \binom{n}{x} \vartheta^x (1-\vartheta)^{n-x} \\ &= \sum_{x=0}^n \binom{n}{x} (\vartheta e^t)^x (1-\vartheta)^{n-x} = \{1 - \vartheta + e^t \vartheta\}^n \end{aligned}$$

Επειδή $M_{S_n}(t) = M_X(t)$ παίρνουμε ότι $S_n \stackrel{d}{=} X \sim Bin(n, \vartheta)$.

Ορισμός: Λέμε ότι η ακολουθία τυχαίων μεταβλητών $\{X_n\}_{n \geq 1}$ συγκλίνει ως προς πιθανότητα στην τ.μ. X (ασθενής σύγκλιση) όταν

$$\lim_{n \rightarrow \infty} P\{|X_n - X| \geq \varepsilon\} = 0, \forall \varepsilon > 0 \Leftrightarrow X_n \xrightarrow[n \rightarrow \infty]{P} X.$$

Ο ασθενής νόμος των μεγάλων αριθμών Δίνεται ακολουθία τ.μ. $\{X_i\}_{i \geq 1}$ που είναι ανεξάρτητες και ταυτοτικά κατανομημένες (iid) με μέση τιμή $\mu < \infty$ τότε για τον δειγματικό μέσο \bar{X}_n ισχύει ότι $\bar{X}_n \xrightarrow[n \rightarrow \infty]{P} \mu$.

Απόδειξη με την επιπρόσθετη συνθήκη $Var[X_i] = \sigma^2 < \infty$.

Από την IID ακολουθία τ.μ. $\{X_i\}_{i \geq 1}$, φτιάχνουμε την ακολουθία $\{\bar{X}_n\}_{n \geq 1}$ όπου

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i. \text{ Η μέση τιμή και η διασπορά της } \bar{X}_n \text{ είναι}$$

$$\mathbb{E}[\bar{X}_n] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i] = \mu,$$

$$\begin{aligned} Var[\bar{X}_n] &= \mathbb{E}[(\bar{X}_n - \mu)^2] = \frac{1}{n^2} \mathbb{E}\left[\left(\sum_{i=1}^n X_i - n\mu\right)^2\right] = \frac{1}{n^2} \mathbb{E}\left[\left(\sum_{i=1}^n (X_i - \mu)\right)^2\right] \\ &= \frac{1}{n^2} \left\{ \sum_{i=1}^n \mathbb{E}[(X_i - \mu)^2] + 2 \sum_{1 \leq i < j \leq n} Cov(X_i, X_j) \right\} = \frac{1}{n^2} \sum_{i=1}^n Var[X_i] = \frac{\sigma^2}{n}. \end{aligned}$$

Από την ανισότητα Chebyshev για την \bar{X}_n έχουμε ότι:

$$P\left\{|\bar{X}_n - \mathbb{E}[\bar{X}_n]| \geq \varepsilon\right\} \leq \frac{Var[\bar{X}_n]}{\varepsilon^2} \text{ ή ότι } P\left\{|\bar{X}_n - \mu| \geq \varepsilon\right\} \leq \frac{\sigma^2}{n\varepsilon^2} \xrightarrow[n \rightarrow \infty]{} 0.$$

Απόδειξη χωρίς την επιπρόσθετη συνθήκη $\sigma^2 < \infty$ (Khinchin)

Εδώ χρειάζεται μόνο η ύπαρξη της μέσης τιμής $\mathbb{E}[X_i] = \mu$. Η απόδειξη μοιάζει με την απόδειξη του Κεντρικού Οριακού Θεωρήματος.

Εάν $\varphi_{X_j}(t) = \varphi(t)$, τότε είναι εύκολο να δείξουμε ότι $\varphi_{\bar{X}_n}(t) = \varphi(t/n)^n$. Επειδή

$$\varphi(t) = \mathbb{E}\left[e^{itX_j}\right] = \mathbb{E}\left[1 + itX_j + \mathcal{O}(t^2)\right] = 1 + it\mu + \mathcal{O}(t^2),$$

$$\text{έχουμε } \varphi_{\bar{X}_n}(t) = \varphi(t/n)^n = \left(1 + \frac{it\mu}{n} + \mathcal{O}\left(\frac{t^2}{n^2}\right)\right)^n, \text{ και παίρνοντας το όριο για } n \rightarrow \infty$$

$$\begin{aligned} \lim_{n \rightarrow \infty} \varphi_{\bar{X}_n}(t) &= \lim_{n \rightarrow \infty} \left(1 + \frac{it\mu}{n} + \mathcal{O}\left(\frac{t^2}{n^2}\right) \right)^n = \lim_{x \rightarrow \infty} \left(1 + \frac{it\mu}{x} + \mathcal{O}\left(\frac{t^2}{x^2}\right) \right)^x \\ &= \exp \left\{ \lim_{x \rightarrow \infty} \frac{1}{x^{-1}} \log \left[1 + \frac{it\mu}{x} + \mathcal{O}\left(\frac{t^2}{x^2}\right) \right] \right\} = \exp(it\mu). \end{aligned}$$

Αλλά η μόνη τ.μ. με χαρακτηριστική συνάρτηση $\exp(it\mu)$ είναι η (τετριμμένη) τ.μ.

$X = \mu$ με $P\{X = \mu\} = 1$. Έτσι έχουμε ότι $\bar{X}_n \xrightarrow[n \rightarrow \infty]{d} \mu$, δηλαδή η τ.μ. \bar{X}_n συγκλίνει κατά νόμο (κατά κατανομή) στην τ.μ. $X = \mu$. Για να τελειώσουμε την απόδειξη, θα πρέπει να δείξουμε και ότι $\bar{X}_n \xrightarrow[n \rightarrow \infty]{P} \mu$.

Γενικά για ακολουθία τ.μ. $Y_n, n \geq 1$, ισχύει ότι $Y_n \xrightarrow[n \rightarrow \infty]{P} Y \Rightarrow Y_n \xrightarrow[n \rightarrow \infty]{d} Y$, αλλά όχι και το αντίστροφο. Στην ειδική περίπτωση όμως που $Y = \text{σταθ.}$ ισχύει και το αντίστροφο, και έχουμε $Y_n \xrightarrow[n \rightarrow \infty]{P} \text{σταθ.} \Leftrightarrow Y_n \xrightarrow[n \rightarrow \infty]{d} \text{σταθ.}$.

Αποδεικνύουμε το τελευταίο για την περίπτωση \Leftarrow

$$Y_n \xrightarrow[n \rightarrow \infty]{d} Y = c = \text{σταθ.} \Leftrightarrow \lim_{n \rightarrow \infty} P\{Y_n \leq y\} = P\{c \leq y\} = 1(c \leq y)$$

$$\begin{aligned} \lim_{n \rightarrow \infty} P\{|Y_n - c| \geq \varepsilon\} &= \lim_{n \rightarrow \infty} P\{Y_n - c \geq \varepsilon\} + \lim_{n \rightarrow \infty} P\{Y_n - c \leq -\varepsilon\} \\ &= \lim_{n \rightarrow \infty} P\{Y_n \geq c + \varepsilon\} + \lim_{n \rightarrow \infty} P\{Y_n \leq c - \varepsilon\} \\ &= 1 - \lim_{n \rightarrow \infty} P\{Y_n < c + \varepsilon\} + \lim_{n \rightarrow \infty} P\{Y_n \leq c - \varepsilon\} \\ &= 1 - 1(c < c + \varepsilon) + 1(c \leq c - \varepsilon) = 1 - 1 - 0 = 0, \forall \varepsilon > 0. \end{aligned}$$