

فصل ۷: دنباله متغیرهای تصادفی

Chapter 7

۱. مفاهیم کلی (pmf ، CDF و pdf مشترک، استقلال، امید ریاضی، کواریانس، تابع مولد گشتاور، توابعی از n متغیر تصادفی، متغیرهای تصادفی مشترکاً نرمال، توزیع‌های شرطی)
۲. کاربردها (مجموع‌های تصادفی، نمونه‌برداری، آماره‌های رتبه، مجموع متغیرهای تصادفی مشترکاً نرمال)
۳. قضیه حد مرکزی
۴. همگرایی دنباله متغیرهای تصادفی
۵. قانون اعداد بزرگ
۶. توابع توزیع متداول در آمار

در فصل ۵ دیدیم که چگونه مفاهیمی را که داشتیم به دو متغیر تصادفی توسعه دهیم. به طریق مشابه، وقتی چندتا متغیر تصادفی داشته باشیم، می‌توانیم مفاهیم گذشته (تابع CDF مشترک، pdf مشترک، مشروط و ...) را مطرح کنیم.

در ابتدا بردار $\underline{\mathbf{x}}$ را به صورت زیر تعریف می‌کنیم:

$$\underline{\mathbf{x}} = \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_n \end{bmatrix}$$

pmf مشترک:

$$P_{\underline{\mathbf{x}}}(\underline{\mathbf{x}}) = P_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) = P\{\mathbf{x}_1 = x_1, \mathbf{x}_2 = x_2, \dots, \mathbf{x}_n = x_n\}$$

که داریم:

$$\underline{\mathbf{x}} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

CDF مشترک:

$$F_{\underline{x}}(\underline{x}) = F_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) = P\{x_1 \leq x_1, x_2 \leq x_2, \dots, x_n \leq x_n\}$$

مقدار این تابع همواره بین صفر و یک است. به ازای تمام آرگومان‌ها صعودی است. در نقطه $(-\infty, -\infty, \dots, -\infty)$ برابر صفر بوده و در نقطه $(+\infty, +\infty, \dots, +\infty)$ برابر یک می‌شود. اگر به جای برخی از آرگومان‌ها بی‌نهایت بگذاریم، CDF مشترک سایر متغیرهای تصادفی حاصل می‌شود. مثلاً داریم:

$$F_{x_1 x_2 x_3}(+\infty, x_2, x_3) = F_{x_2 x_3}(x_2, x_3)$$

pdf مشترک:

$$f_{\underline{x}}(\underline{x}) = f_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) = \frac{\partial^n}{\partial x_1 \partial x_2 \dots \partial x_n} F_{\underline{x}}(\underline{x}) = \frac{\partial^n}{\partial x_1 \partial x_2 \dots \partial x_n} F_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n)$$

به این ترتیب روابط زیر برقرار خواهند بود:

$$f_{\underline{x}}(\underline{x}) dx_1 dx_2 \dots dx_n = P\{x_1 \leq \mathbf{x}_1 \leq x_1 + dx_1, x_2 \leq \mathbf{x}_2 \leq x_2 + dx_2, \dots, x_n \leq \mathbf{x}_n \leq x_n + dx_n\}$$

$$F_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_n} f_{x_1 x_2 \dots x_n}(u_1, u_2, \dots, u_n) du_n \dots du_2 du_1$$

مقدار تابع pdf همواره مثبت است. انتگرال n گانه آن از $-\infty$ تا $+\infty$ یک می شود. همچنین داریم:

$$\forall D \subset \mathbb{R}^n : P\{(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) \in D\} = \int_D \dots \int_D f_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) dx_1 \dots dx_n = \int_D f_{\underline{x}}(\underline{x}) d\underline{x}$$

اگر از $-\infty$ تا $+\infty$ روی برخی از آرگومان ها انتگرال بگیریم، pdf مشترک سایر متغیرهای تصادفی حاصل می شود. مثلاً داریم:

$$f_{x_2 x_3}(x_2, x_3) = \int_{-\infty}^{+\infty} f_{x_1 x_2 x_3}(x_1, x_2, x_3) dx_1$$

استقلال:

متغیرهای تصادفی x_1, x_2, \dots, x_n را مستقل گویند، هرگاه واقعه‌های $\{x_1 \leq x_1\}$ ، $\{x_2 \leq x_2\}$ ، ... و $\{x_n \leq x_n\}$ برای هر x_1, x_2, \dots, x_n مستقل باشند.

معادلاً x_i ها را مستقل گویند، هرگاه برای هر x_1, x_2, \dots, x_n داشته باشیم:

$$F_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) = F_{x_1}(x_1) F_{x_2}(x_2) \dots F_{x_n}(x_n) = \prod_{i=1}^n F_{x_i}(x_i)$$

یا معادلاً:

$$f_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) = f_{x_1}(x_1) f_{x_2}(x_2) \dots f_{x_n}(x_n) = \prod_{i=1}^n f_{x_i}(x_i)$$

(در این صورت در مورد هر زیرمجموعه از اندیس‌ها نیز برقرار خواهد بود.)

مشابه حالت دو بعدی می‌توان ثابت کرد که اگر x_i ها مستقل باشند، $g_i(x_i)$ ها هم مستقل خواهند بود.

همچنین داریم:

$$\underbrace{\boxed{\text{گروه A}}}_{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m}, \underbrace{\boxed{\text{گروه B}}}_{\mathbf{x}_{m+1}, \dots, \mathbf{x}_n}$$

گروه A از گروه B مستقل است، اگر:

$$f_{\mathbf{x}_1 \mathbf{x}_2 \dots \mathbf{x}_n}(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) = f_{\mathbf{x}_1 \mathbf{x}_2 \dots \mathbf{x}_m}(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m) f_{\mathbf{x}_{m+1} \dots \mathbf{x}_n}(\mathbf{x}_{m+1}, \dots, \mathbf{x}_n)$$

امید ریاضی:

اگر $\mathbf{z} = g(\underline{\mathbf{x}})$ باشد، داریم:

$$E(\mathbf{z}) = \int_{-\infty}^{+\infty} z f_z(z) dz$$

ولی بدون محاسبه f_z نیز می‌توان $E(\mathbf{z})$ را حساب کرد:

$$E(\mathbf{z}) = E[g(\underline{\mathbf{x}})] = \int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} g(\underline{\mathbf{x}}) f_{\underline{\mathbf{x}}}(\underline{\mathbf{x}}) d\underline{\mathbf{x}} \quad (\text{این انتگرال } n \text{ بُعدی است})$$

و مشابه حالت دو بُعدی، از اینجا می‌توان خطی بودن امید ریاضی را ثابت کرد:

$$E\left[\sum_{i=1}^n a_i g_i(\underline{\mathbf{x}})\right] = \sum_{i=1}^n a_i E[g_i(\underline{\mathbf{x}})] \quad (\text{یعنی جای امید و مجموع را می‌توان عوض کرد})$$

از جمله داریم:

$$E\left[\sum_{i=1}^n a_i \mathbf{x}_i\right] = \sum_{i=1}^n a_i E(\mathbf{x}_i)$$

برای درک نحوه توزیع هر \mathbf{x}_i ، η_i و σ_i به ما کمک می‌کنند که ایده‌های کلی از نحوه توزیع آن به دست آوریم. داریم:

$$\underline{\mathbf{x}} = \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_n \end{bmatrix} \rightarrow \eta_{\underline{\mathbf{x}}} = E(\underline{\mathbf{x}}) = \begin{bmatrix} E(\mathbf{x}_1) \\ E(\mathbf{x}_2) \\ \vdots \\ E(\mathbf{x}_n) \end{bmatrix} = \begin{bmatrix} \eta_1 \\ \eta_2 \\ \vdots \\ \eta_n \end{bmatrix} \text{ (بردار میانگین)}$$

و نیز دیده بودیم که کواریانس دو متغیر تصادفی، نحوه بستگی آنها را به هم نشان می‌داد. حال با کواریانس دو به دوی این n تا متغیر تصادفی رو به رو هستیم:

$$\sigma_{ij} \triangleq \mu_{\mathbf{x}_i \mathbf{x}_j} = \text{cov}(\mathbf{x}_i, \mathbf{x}_j) = E[(\mathbf{x}_i - \eta_i)(\mathbf{x}_j - \eta_j)] : i, j : 1, 2, \dots, n$$

$$\sigma_{ii} = \text{cov}(\mathbf{x}_i, \mathbf{x}_i) = \text{var}(\mathbf{x}_i) = \sigma_i^2$$

ماتریس کواریانس $\underline{\mathbf{x}}$ (Covariance Matrix) طبق تعریف برابر است با:

$$\mathbf{C}_{\underline{\mathbf{x}}} = E[(\underline{\mathbf{x}} - \eta_{\underline{\mathbf{x}}}) \cdot (\underline{\mathbf{x}} - \eta_{\underline{\mathbf{x}}})^T] = E \left(\begin{bmatrix} \mathbf{x}_1 - \eta_1 \\ \mathbf{x}_2 - \eta_2 \\ \vdots \\ \mathbf{x}_n - \eta_n \end{bmatrix} \cdot [\mathbf{x}_1 - \eta_1 \quad \mathbf{x}_2 - \eta_2 \quad \cdots \quad \mathbf{x}_n - \eta_n] \right) = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{bmatrix}$$

(گاهی آن را با $\mathbf{C}_{\underline{\mathbf{x}}\underline{\mathbf{x}}}$ نیز نشان داده و آن را Auto Covariance هم می‌نامند.)

خواص ماتریس کواریانس:

۱. متقارن است، یعنی: $C = C^T$ ، زیرا: $\sigma_{ij} = \sigma_{ji}$.

۲. معین نامنفی (Nonnegative Definite) است، یعنی: برای هر بردار دلخواه \underline{a} داریم:

$$\underline{a}^T C \underline{a} \geq 0$$

(اثبات این قضیه در تمرین‌ها خواسته شده است.)

از جمله خواص ماتریس‌های معین نامنفی این است که دترمینان آنها نامنفی است، پس داریم:

$$\det(C) \geq 0$$

ماتریس همبستگی \underline{x} (Correlation Matrix) طبق تعریف برابر است با:

$$R_{\underline{x}} = E(\underline{x} \cdot \underline{x}^T)$$

از تعریف ماتریس‌های کواریانس و همبستگی نتیجه می‌شود:

$$C_{\underline{\mathbf{x}}} = R_{\underline{\mathbf{x}}} - \underline{\eta}_{\underline{\mathbf{x}}} \cdot \underline{\eta}_{\underline{\mathbf{x}}}^T$$

$$(\sigma^2 = E(\mathbf{x}^2) - (E(\mathbf{x}))^2 \text{ شبیه به رابطه})$$

در حالت کلی‌تر، می‌توانیم ماتریس‌های زیر را تعریف کنیم:

$$C_{\underline{\mathbf{x}}\underline{\mathbf{y}}} = \text{cov}(\underline{\mathbf{x}}, \underline{\mathbf{y}}) = E\left[(\underline{\mathbf{x}} - \underline{\eta}_{\underline{\mathbf{x}}})(\underline{\mathbf{y}} - \underline{\eta}_{\underline{\mathbf{y}}})^T\right] : \text{Cross Covariance}$$

$$R_{\underline{\mathbf{x}}\underline{\mathbf{y}}} = E(\underline{\mathbf{x}} \cdot \underline{\mathbf{y}}^T) : \text{Cross Correlation}$$

اگر $\mathbf{z} = \sum_{i=1}^n a_i \mathbf{x}_i$ باشد، خواهیم داشت:

$$E(\mathbf{z}) = \sum_{i=1}^n a_i E(\mathbf{x}_i) = \sum_{i=1}^n a_i \eta_i$$

$$\text{var}(\mathbf{z}) = E\left[(\mathbf{z} - \eta_{\mathbf{z}})^2\right] = E\left[\left(\sum_{i=1}^n a_i (\mathbf{x}_i - \eta_i)\right)^2\right] = E\left[\sum_{i=1}^n \sum_{j=1}^n a_i a_j (\mathbf{x}_i - \eta_i)(\mathbf{x}_j - \eta_j)\right] = \sum_{i=1}^n \sum_{j=1}^n a_i a_j \sigma_{ij}$$

یعنی اگر $\mathbf{z} = \underline{\mathbf{a}}^T \underline{\mathbf{x}}$ باشد، داریم:

$$\eta_{\mathbf{z}} = \underline{\mathbf{a}}^T \eta_{\mathbf{x}}$$

$$\sigma_{\mathbf{z}}^2 = \underline{\mathbf{a}}^T \mathbf{C}_{\mathbf{x}} \underline{\mathbf{a}}$$

زیرا:

$$\sigma_{\mathbf{z}}^2 = E\left[(\mathbf{z} - \eta_{\mathbf{z}})^2\right] = E\left[\underline{\mathbf{a}}^T (\underline{\mathbf{x}} - \eta_{\mathbf{x}}) \cdot (\underline{\mathbf{x}} - \eta_{\mathbf{x}})^T \underline{\mathbf{a}}\right] = \underline{\mathbf{a}}^T E\left[(\underline{\mathbf{x}} - \eta_{\mathbf{x}}) \cdot (\underline{\mathbf{x}} - \eta_{\mathbf{x}})^T\right] \underline{\mathbf{a}} = \underline{\mathbf{a}}^T \mathbf{C}_{\mathbf{x}} \underline{\mathbf{a}}$$

\mathbf{x}_i ها را ناهمبسته گوییم، اگر برای هر $i \neq j$ داشته باشیم: $\sigma_{ij} = 0$ ؛ یعنی $\mathbf{C}_{\mathbf{x}}$ قطری باشد.

در این صورت خواهیم داشت:

$$\sigma_{\mathbf{z}}^2 = \sum_{i=1}^n a_i^2 \sigma_i^2 \quad (\text{اصل سوپر پوزیشن قدرت})$$

\mathbf{x}_i ها را متعامد گوییم، اگر برای هر $i \neq j$ داشته باشیم: $E(\mathbf{x}_i \mathbf{x}_j) = 0$ ؛ یعنی $\mathbf{R}_{\mathbf{x}}$ قطری باشد.

مشابه حالت دو بُعدی به سادگی می توان نشان داد که:

اگر \mathbf{x}_i ها مستقل باشند، ناهمبسته هم خواهند بود. همچنین $g_i(\mathbf{x}_i)$ ها نیز ناهمبسته خواهند بود.

تابع مولد گشتاور و تابع مشخصه:

$$\Phi_{\underline{x}}(s_1, s_2, \dots, s_n) = E(e^{s_1 \mathbf{x}_1 + s_2 \mathbf{x}_2 + \dots + s_n \mathbf{x}_n}) = E(e^{\sum_{i=1}^n s_i \mathbf{x}_i})$$

$$\Phi_{\underline{x}}(j\omega_1, j\omega_2, \dots, j\omega_n) = E(e^{j\omega_1 \mathbf{x}_1 + j\omega_2 \mathbf{x}_2 + \dots + j\omega_n \mathbf{x}_n}) = E(e^{j \sum_{i=1}^n \omega_i \mathbf{x}_i})$$

به این ترتیب خواهیم داشت:

$$\frac{1}{j^{k_1 + k_2 + \dots + k_n}} \frac{\partial^{k_1} \partial^{k_2} \dots \partial^{k_n}}{\partial \omega_1 \partial \omega_2 \dots \partial \omega_n} \Phi_{\underline{x}}(j\omega_1, j\omega_2, \dots, j\omega_n) \Big|_{\omega_1 = \omega_2 = \dots = \omega_n = 0} = E(\mathbf{x}_1^{k_1} \mathbf{x}_2^{k_2} \dots \mathbf{x}_n^{k_n})$$

اگر $\mathbf{z} = \sum_{i=1}^n \mathbf{x}_i$ باشد، داریم:

$$\Phi_{\mathbf{z}}(j\omega) = E(e^{j\omega \mathbf{z}}) = E(e^{j \sum_{i=1}^n \omega \mathbf{x}_i}) = \Phi_{\underline{x}}(j\omega, j\omega, \dots, j\omega)$$

همچنین x_i ها مستقلند، اگر و فقط اگر داشته باشیم:

$$\Phi_{\underline{x}}(j\omega_1, j\omega_2, \dots, j\omega_n) = \Phi_{x_1}(j\omega_1) \Phi_{x_2}(j\omega_2) \cdots \Phi_{x_n}(j\omega_n) = \prod_{i=1}^n \Phi_{x_i}(j\omega_i)$$

توابعی از n متغیر تصادفی:

اگر یک تابع از n متغیر تصادفی داشته باشیم، از چهار روشی که قبلاً در حالت دو متغیر تصادفی گفته بودیم، در اینجا نیز می‌توان برای به دست آوردن توزیع آن استفاده کرد.

مثال: متغیرهای تصادفی x_1 ، x_2 و x_3 مستقل بوده و همگی $N(0,1)$ هستند. اگر $v = x_1^2 + x_2^2 + x_3^2$ باشد، داریم:

$$F_v(v) = P\{v \leq v\} = P\{x_1^2 + x_2^2 + x_3^2 \leq v\}$$

برای $v < 0$:

$$F_v(v) = 0$$

برای $v > 0$:

$$F_v(v) = \iiint_{x_1^2 + x_2^2 + x_3^2 \leq v} f_{x_1 x_2 x_3}(x_1, x_2, x_3) dx_1 dx_2 dx_3$$

چون x_1 ، x_2 و x_3 مستقل بوده و همگی $N(0,1)$ هستند، پس:

$$f_{x_1 x_2 x_3}(x_1, x_2, x_3) = \frac{1}{(2\pi)^{\frac{3}{2}}} e^{-\frac{x_1^2 + x_2^2 + x_3^2}{2}}$$

(چنین توزیع‌هایی را که فقط تابع r (فاصله از مبدأ) هستند، متقارن کروی گویند. استقلال و تقارن کروی، نرمال بودن را نتیجه می‌دهند.)

پس:

$$F_{\mathbf{v}}(\mathbf{v}) = \frac{1}{(2\pi)^{\frac{3}{2}}} \iiint_{\substack{\text{داخل کره‌ای} \\ \text{به شعاع } \sqrt{v}}} e^{-\frac{x_1^2+x_2^2+x_3^2}{2}} dx_1 dx_2 dx_3$$

با تبدیل به مختصات کروی خواهیم داشت:

$$\begin{cases} x_1 = r \sin \varphi \cos \theta \\ x_2 = r \sin \varphi \sin \theta \\ x_3 = r \cos \varphi \end{cases}$$

پس در نهایت داریم:

$$F_{\mathbf{v}}(\mathbf{v}) = \frac{1}{(2\pi)^{\frac{3}{2}}} \int_0^{2\pi} \int_0^{\pi} \int_0^{\sqrt{\mathbf{v}}} e^{-\frac{r^2}{2}} r^2 \sin \varphi \, dr \, d\varphi \, d\theta = \frac{1}{(2\pi)^{\frac{3}{2}}} \int_0^{2\pi} d\theta \int_0^{\pi} \sin \varphi \, d\varphi \int_0^{\sqrt{\mathbf{v}}} r^2 e^{-\frac{r^2}{2}} \, dr$$
$$= \frac{(2\pi)(2)}{(2\pi)^{\frac{3}{2}}} \int_0^{\sqrt{\mathbf{v}}} r^2 e^{-\frac{r^2}{2}} \, dr$$

$$f_{\mathbf{v}}(\mathbf{v}) = \frac{d}{d\mathbf{v}} F_{\mathbf{v}}(\mathbf{v}) = \frac{2}{\sqrt{2\pi}} \cdot \frac{1}{2\sqrt{\mathbf{v}}} \mathbf{v} e^{-\frac{\mathbf{v}}{2}} = \frac{1}{\sqrt{2\pi}} \mathbf{v}^{\frac{1}{2}} e^{-\frac{\mathbf{v}}{2}} : \mathbf{v} > 0$$

که توزیع χ^2 با سه درجه آزادی است.

اگر n تابع از n متغیر تصادفی داشته باشیم، یعنی:

$$\begin{cases} y_1 = g_1(x_1, x_2, \dots, x_n) \\ y_2 = g_2(x_1, x_2, \dots, x_n) \\ \vdots \\ y_n = g_n(x_1, x_2, \dots, x_n) \end{cases} \rightarrow \underline{y} = \underline{g}(\underline{x})$$

ابتدا دستگاه $\underline{y} = \underline{g}(\underline{x})$ را حل می‌کنیم. اگر ریشه آن برابر با $\underline{h}(\underline{y})$ باشد، خواهیم داشت:

$$\underline{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} h_1(\underline{y}) \\ h_2(\underline{y}) \\ \vdots \\ h_n(\underline{y}) \end{bmatrix} = \underline{h}(\underline{y})$$

$$f_{\underline{y}}(\underline{y}) = \frac{f_{\underline{x}}(x_1, x_2, \dots, x_n)}{|J(x_1, x_2, \dots, x_n)|} = \frac{f_{\underline{x}}(\underline{h}(\underline{y}))}{|J(\underline{h}(\underline{y}))|}$$

که:

$$J(x_1, x_2, \dots, x_n) = \det \begin{bmatrix} \frac{\partial g_1}{\partial x_1} & \dots & \frac{\partial g_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial g_n}{\partial x_1} & \dots & \frac{\partial g_n}{\partial x_n} \end{bmatrix}$$

یا معادلاً:

$$f_{\underline{y}}(\underline{y}) = f_{\underline{x}}(\underline{h}(\underline{y})) \left| \det \begin{bmatrix} \frac{\partial h_1}{\partial y_1} & \dots & \frac{\partial h_1}{\partial y_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial h_n}{\partial y_1} & \dots & \frac{\partial h_n}{\partial y_n} \end{bmatrix} \right|$$

(اگر چند ریشه وجود داشته باشد، عبارت فوق را در تمام ریشه‌ها حساب کرده و جمع می‌کنیم.)

مثال: اگر $\underline{y} = A\underline{x}$ باشد، یعنی: $\underline{y}_i = \sum_{j=1}^n a_{ij} \underline{x}_j : i = 1, 2, \dots, n$ ، $f_{\underline{y}}$ ، $\eta_{\underline{y}}$ و $C_{\underline{y}}$ را پیدا کنید.

$$\underline{y} = A\underline{x} \Rightarrow \underline{x} = A^{-1}\underline{y}$$

$$J = \det(A)$$

$$f_{\underline{y}}(\underline{y}) = \frac{f_{\underline{x}}(A^{-1}\underline{y})}{|\det(A)|}$$

$$\eta_{\underline{y}} = E(\underline{y}) = E(A\underline{x}) = A\eta_{\underline{x}}$$

$$C_{\underline{y}} = E\left[(\underline{y} - \eta_{\underline{y}}) \cdot (\underline{y} - \eta_{\underline{y}})^T\right] = E\left[(A\underline{x} - A\eta_{\underline{x}}) \cdot (A\underline{x} - A\eta_{\underline{x}})^T\right] = E\left[A(\underline{x} - \eta_{\underline{x}}) \cdot (\underline{x} - \eta_{\underline{x}})^T A^T\right] = AC_{\underline{x}}A^T$$

برای مثال داریم:

$$\begin{cases} \mathbf{y}_1 = \mathbf{x}_1 \\ \mathbf{y}_2 = \mathbf{x}_1 + \mathbf{x}_2 \\ \vdots \\ \mathbf{y}_n = \mathbf{x}_1 + \mathbf{x}_2 + \dots + \mathbf{x}_n \end{cases} \Rightarrow \mathbf{A} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 1 & 1 & 0 & \dots & 0 \\ 1 & 1 & 1 & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & 0 \\ 1 & 1 & 1 & \dots & 1 \end{bmatrix} \Rightarrow \det(\mathbf{A}) = 1$$

$$\underline{\mathbf{y}} = \mathbf{A}\underline{\mathbf{x}} \Rightarrow \begin{cases} \mathbf{x}_1 = \mathbf{y}_1 \\ \mathbf{x}_2 = \mathbf{y}_2 - \mathbf{y}_1 \\ \mathbf{x}_3 = \mathbf{y}_3 - \mathbf{y}_2 \\ \vdots \\ \mathbf{x}_n = \mathbf{y}_n - \mathbf{y}_{n-1} \end{cases}$$

$$f_{\underline{\mathbf{y}}}(\underline{\mathbf{y}}) = f_{\underline{\mathbf{x}}}(\mathbf{y}_1, \mathbf{y}_2 - \mathbf{y}_1, \mathbf{y}_3 - \mathbf{y}_2, \dots, \mathbf{y}_n - \mathbf{y}_{n-1})$$

حال اگر \mathbf{x}_i ها مستقل باشند، $f_{\underline{\mathbf{x}}}(\underline{\mathbf{x}}) = f_{\mathbf{x}_1}(\mathbf{x}_1)f_{\mathbf{x}_2}(\mathbf{x}_2)\dots f_{\mathbf{x}_n}(\mathbf{x}_n)$ و لذا:

$$f_{\underline{\mathbf{y}}}(\underline{\mathbf{y}}) = f_{\mathbf{x}_1}(\mathbf{y}_1)f_{\mathbf{x}_2}(\mathbf{y}_2 - \mathbf{y}_1)f_{\mathbf{x}_3}(\mathbf{y}_3 - \mathbf{y}_2)\dots f_{\mathbf{x}_n}(\mathbf{y}_n - \mathbf{y}_{n-1})$$

متغیرهای تصادفی مشترکاً نرمال:

تعریف: متغیرهای تصادفی x_1, x_2, \dots, x_n را مشترکاً نرمال گویند، هرگاه $z = \sum_{i=1}^n a_i x_i$ برای هر a_i نرمال باشد.

توابع $f_{\underline{x}}$ و $\Phi_{\underline{x}}$ برای متغیرهای تصادفی مشترکاً نرمال به صورت تابعی نمایشی از یک فرم درجه دوم هستند:

$$f_{\underline{x}}(\underline{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{\det(C_{\underline{x}})}} \exp\left[-\frac{1}{2}(\underline{x} - \eta_{\underline{x}})^T C_{\underline{x}}^{-1} (\underline{x} - \eta_{\underline{x}})\right]$$

یعنی $f_{\underline{x}}$ به صورت $\alpha e^{-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \gamma_{ij} (x_i - \eta_i)(x_j - \eta_j)}$ است که γ_{ij} ها همان درایه‌های $C_{\underline{x}}^{-1}$ هستند.

$$\Phi_{\underline{x}}(j\omega) = e^{j\omega^T \eta_{\underline{x}}} e^{-\frac{1}{2} \omega^T C_{\underline{x}} \omega}$$

یعنی $\Phi_{\underline{x}}$ به صورت $e^{j \sum_{i=1}^n \omega_i \eta_i} e^{-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \sigma_{ij} \omega_i \omega_j}$ می‌باشد.

(این فرمول‌ها در حالت دو بُعدی به همان فرمول‌هایی که در فصل ۵ داشتیم تبدیل می‌شوند.)

ملاحظه می‌شود که در حالت مشترکاً نرمال، بردار میانگین و ماتریس کواریانس کلیه خواص آماری x_1, x_2, \dots, x_n را مشخص می‌کنند.

قضیه: اگر هر یک از متغیرهای تصادفی x_1, x_2, \dots, x_n نرمال بوده و مستقل نیز باشند، آنگاه مشترکاً نرمال خواهند بود.

(زیرا $\prod_{i=1}^n f_{x_i}$ همان شکل فوق را خواهد داشت.)

قضیه: اگر متغیرهای تصادفی x_1, x_2, \dots, x_n مشترکاً نرمال بوده و ناهمبسته نیز باشند، آنگاه مستقل خواهند بود.

اثبات:

$$\sigma_{ij} = 0 : i \neq j \Rightarrow C_{\underline{x}} = \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \sigma_n^2 \end{bmatrix}$$

$$\Rightarrow f_{\underline{x}}(\underline{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{\prod_{i=1}^n \sigma_i^2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \frac{(x_i - \eta_i)^2}{\sigma_i^2} \right\} = \prod_{i=1}^n f_{x_i}(x_i)$$

(یا می‌توان نشان داد که: $(\Phi_{\underline{x}}(j\omega)) = \prod_{i=1}^n \Phi_{x_i}(j\omega_i)$)


قضیه: اگر متغیرهای تصادفی $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ و $\underline{\mathbf{y}} = \mathbf{A}\underline{\mathbf{x}}$ باشد، یعنی: $\mathbf{y}_i = \sum_{j=1}^n a_{ij} \mathbf{x}_j : i = 1, 2, \dots, m$ ، \mathbf{y}_i ها هم مشترکاً نرمال خواهند بود.
اثبات:

$$\mathbf{z} = \sum_{i=1}^m c_i \mathbf{y}_i = \sum_{i=1}^m c_i \sum_{j=1}^n a_{ij} \mathbf{x}_j = \sum_{j=1}^n \underbrace{\left(\sum_{i=1}^m c_i a_{ij} \right)}_{b_j} \mathbf{x}_j = \sum_{j=1}^n b_j \mathbf{x}_j \rightarrow \text{بنا به فرض دارای توزیع نرمال است}$$

یا می‌توانیم به صورت برداری نیز نشان دهیم:

$$\mathbf{z} = \mathbf{C}^T \underline{\mathbf{y}} = \mathbf{C}^T (\mathbf{A}\underline{\mathbf{x}}) = (\mathbf{C}^T \mathbf{A}) \underline{\mathbf{x}} = \mathbf{b}^T \underline{\mathbf{x}} \rightarrow \text{بنا به فرض دارای توزیع نرمال است}$$

کاربرد:



توزیع‌های شرطی:

مشابه حالت دو بُعدی در اینجا نیز داریم:

$$f_{x_1 x_2 \dots x_k}(x_1, x_2, \dots, x_k | x_{k+1} = x_{k+1}, \dots, x_n = x_n) = \frac{f_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n)}{f_{x_{k+1} \dots x_n}(x_{k+1}, \dots, x_n)} \quad (*)$$

مثلاً داریم:

$$f_{x_1 x_2}(x_1, x_2 | x_3, x_4) = \frac{f_{x_1 x_2 x_3 x_4}(x_1, x_2, x_3, x_4)}{f_{x_3 x_4}(x_3, x_4)}$$

با استفاده از رابطه (*) می‌توان نشان داد که:

قاعده زنجیری:

$$f_{x_1 x_2 \dots x_n}(x_1, x_2, \dots, x_n) = f_{x_1}(x_1) f_{x_2}(x_2 | x_1) f_{x_3}(x_3 | x_2, x_1) \dots f_{x_n}(x_n | x_1, x_2, \dots, x_{n-1})$$

حذف متغیر سمت چپ در چگالی شرطی:

می‌دانیم که اگر $f_{x_1, x_2}(x_1, x_2)$ را داشته باشیم و بخواهیم f_{x_1} را به دست آوریم، کافی است روی f_{x_1, x_2} از $-\infty$ تا $+\infty$ نسبت به x_2 انتگرال بگیریم. در چگالی شرطی نیز به همین ترتیب عمل می‌کنیم. یعنی مثلاً اگر بخواهیم از $f_{x_1, x_2}(x_1, x_2 | x_3)$ مقدار $f_{x_1}(x_1 | x_3)$ را به دست آوریم (توجه کنید که عین خواص pdf معمولی برقرار است)، خواهیم داشت:

$$f_{x_1}(x_1 | x_3) = \int_{-\infty}^{+\infty} f_{x_1, x_2}(x_1, x_2 | x_3) dx_2$$

(برای اثبات از تعریف چگالی شرطی و رابطه چگالی مشترک حاشیه‌ای استفاده کنید.)

حذف متغیر سمت راست در چگالی شرطی:

اگر بخواهیم از $f_{x_1}(x_1 | x_2, x_3)$ به $f_{x_1}(x_1 | x_3)$ برسیم، داریم:

$$f_{x_1}(x_1 | x_3) = \int_{-\infty}^{+\infty} f_{x_1}(x_1 | x_2, x_3) f_{x_2}(x_2 | x_3) dx_2$$

زیرا:

$$f_{x_1}(x_1 | x_2, x_3) f_{x_2}(x_2 | x_3) = f_{x_1 x_2}(x_1, x_2 | x_3)$$

لذا:

$$f_{x_1}(x_1 | x_3) = \int_{-\infty}^{+\infty} f_{x_1}(x_1 | x_2, x_3) f_{x_2}(x_2 | x_3) dx_2 \quad (\text{معادله چایمن - کولموگروف})$$

اگر x_i ها مستقل باشند، چگالی مشروط بعضی از آنها بر بعضی دیگر با چگالی غیرمشروط یکسان است. مثلاً:

$$f_{x_1 x_2}(x_1, x_2 | x_3, x_4) = f_{x_1 x_2}(x_1, x_2)$$

متوسط مشروط:

$$E(\mathbf{y} | \mathbf{x}_1 = x_1, \mathbf{x}_2 = x_2, \dots, \mathbf{x}_n = x_n) = E(\mathbf{y} | x_1, x_2, \dots, x_n) = \int_{-\infty}^{+\infty} y f_{\mathbf{y}}(y | x_1, x_2, \dots, x_n) dy$$

(که تابعی از x_1, x_2, \dots, x_n است، نه y .)

$$E(g(\mathbf{y}) | \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) = \int_{-\infty}^{+\infty} g(y) f_{\mathbf{y}}(y | x_1, x_2, \dots, x_n) dy$$

(که تابعی از x_1, x_2, \dots, x_n است، نه y .)

حال اگر فرض کنیم:

$$E(\mathbf{y} | \underline{\mathbf{x}}) = \Phi(\underline{\mathbf{x}})$$

متناظر با این تابع می‌توانیم متغیر تصادفی $\Phi(\underline{\mathbf{x}})$ را تعریف کنیم:

$$E(\mathbf{y} | \underline{\mathbf{x}}) = \Phi(\underline{\mathbf{x}})$$

مشابه قبل به سادگی می توان نشان داد که:

$$E[E(\mathbf{y} | \underline{\mathbf{x}})] = E(\mathbf{y})$$

و اگر \mathbf{x} و \mathbf{y} مستقل باشند، خواهیم داشت:

$$E(\mathbf{y} | \underline{\mathbf{x}}) = E(\mathbf{y})$$

$E(\mathbf{y} | \underline{\mathbf{x}})$ در واقع تخمین بهینه (به مفهوم mse) برای \mathbf{y} بر مبنای مشاهده $\underline{\mathbf{x}}$ است.

برخی کاربردهای توزیع شرطی و دنباله متغیرهای تصادفی:

۱. مجموعهای تصادفی (Random Sums):

فرض کنید $y = \sum_{i=1}^N x_i$ باشد که در آن، x_i ها متغیرهای تصادفی مستقل بوده و نیز داریم:

$$\forall i: E(x_i) = \eta_x, \text{var}(x_i) = \sigma_x^2$$

از طرف دیگر، خود N نیز یک متغیر تصادفی با میانگین η_N و واریانس σ_N^2 باشد و x_i ها از N نیز مستقل باشند.

مثلاً y می تواند سود روزانه یک مغازه، x_i سود حاصل از هر مشتری و N تعداد مشتری هایی که در روز مراجعه می کنند، باشد. یا در مسأله Multipath Fading یا انرژی کل الکترون های منتشر شده از یک ماده رادیواکتیو (N دارای توزیع پواسون).

حال می‌خواهیم میانگین و واریانس \mathbf{y} را به دست آوریم:

$$E(\mathbf{y}) = E[E(\mathbf{y} | \mathbf{N})]$$

$$E(\mathbf{y} | \mathbf{N} = n) = E\left(\sum_{i=1}^n (\mathbf{x}_i | n)\right) = \sum_{i=1}^n E(\mathbf{x}_i | n) = \sum_{i=1}^n E(\mathbf{x}_i)$$

ولی داشتیم:

$$\forall i: E(\mathbf{x}_i) = \eta_{\mathbf{x}}$$

پس داریم:

$$E(\mathbf{y} | n) = n\eta_{\mathbf{x}}$$

$$\Rightarrow E(\mathbf{y} | \mathbf{N}) = \mathbf{N}\eta_{\mathbf{x}}$$

$$\Rightarrow E(\mathbf{y}) = E[E(\mathbf{y} | \mathbf{N})] = E(\mathbf{N}\eta_{\mathbf{x}}) = \eta_{\mathbf{x}}E(\mathbf{N}) = \eta_{\mathbf{x}}\eta_{\mathbf{N}}$$

$$E(\mathbf{y}^2 | n) = E \left[\left(\sum_{i=1}^n \mathbf{x}_i \right)^2 \right] = E \left(\sum_{i=1}^n \sum_{j=1}^n \mathbf{x}_i \mathbf{x}_j \right) = \sum_{i=1}^n \sum_{j=1}^n E(\mathbf{x}_i \mathbf{x}_j)$$

به دلیل استقلال \mathbf{x}_i ها، برای $i \neq j$ داریم:

$$E(\mathbf{x}_i \mathbf{x}_j) = E(\mathbf{x}_i) E(\mathbf{x}_j)$$

در نتیجه:

$$E(\mathbf{y}^2 | n) = \sum_{i=1}^n E(\mathbf{x}_i^2) + \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n E(\mathbf{x}_i) E(\mathbf{x}_j)$$

ولی داشتیم:

$$\forall i: \text{var}(\mathbf{x}_i) = \sigma_{\mathbf{x}}^2$$

پس خواهیم داشت:

$$E(\mathbf{y}^2 | n) = n(\sigma_{\mathbf{x}}^2 + \eta_{\mathbf{x}}^2) + (n^2 - n)\eta_{\mathbf{x}}^2 = n\sigma_{\mathbf{x}}^2 + n^2\eta_{\mathbf{x}}^2$$

$$\Rightarrow E(\mathbf{y}^2 | \mathbf{N}) = \mathbf{N}\sigma_{\mathbf{x}}^2 + \mathbf{N}^2\eta_{\mathbf{x}}^2$$

$$E(\mathbf{y}^2) = E \left[E(\mathbf{y}^2 | \mathbf{N}) \right] = \sigma_{\mathbf{x}}^2 E(\mathbf{N}) + \eta_{\mathbf{x}}^2 E(\mathbf{N}^2) = \sigma_{\mathbf{x}}^2 \eta_{\mathbf{N}} + \eta_{\mathbf{x}}^2 (\sigma_{\mathbf{N}}^2 + \eta_{\mathbf{N}}^2)$$

$$\Rightarrow \sigma_{\mathbf{y}}^2 = E(\mathbf{y}^2) - (E(\mathbf{y}))^2 = \sigma_{\mathbf{x}}^2 \eta_{\mathbf{N}} + \eta_{\mathbf{x}}^2 \sigma_{\mathbf{N}}^2 + \eta_{\mathbf{x}}^2 \eta_{\mathbf{N}}^2 - \eta_{\mathbf{x}}^2 \eta_{\mathbf{N}}^2 = \sigma_{\mathbf{x}}^2 \eta_{\mathbf{N}} + \eta_{\mathbf{x}}^2 \sigma_{\mathbf{N}}^2$$

۲. نمونه برداری:

متغیر تصادفی X را طول قد مردان ایرانی در نظر گرفته و فرض کنیم (بنابر استدلالات یا مشاهده طولانی) که دارای چگالی f_X و توزیع F_X باشد (مثلاً $N(170, 10)$). حال مردی را به عنوان نمونه (به طور کاملاً تصادفی) انتخاب کنیم و از شما سؤال کنیم احتمال اینکه قد این مرد کوچکتر از x باشد، چقدر است؟

خواهید گفت:

$$P\{x_1 \leq x\} = F_X(x)$$

به همین ترتیب برای سایر نمونه‌ها نیز داریم:

$$F_{x_i}(x) = F_X(x), f_{x_i}(x) = f_X(x)$$

از سوی دیگر، با فرض استقلال آزمایشها، x_i ها مستقلند (تعداد نمونه‌ها باید نسبت به تعداد افراد جامعه کم باشد یا نمونه برداری با جایگزینی باشد).

یا مثلاً اگر متغیر تصادفی \mathbf{x} ، قطر پیچ‌های تولیدی یک کارخانه باشد و فرض کنیم دارای چگالی $f_{\mathbf{x}}$ باشد، این مدلی است که طبق فرض برای کلیه \mathbf{x} ها صادق است. پس اگر \mathbf{x}_i قطر پیچ نمونه i ام باشد، داریم:

$$f_{\mathbf{x}_i}(\mathbf{x}) = f_{\mathbf{x}}(\mathbf{x})$$

و \mathbf{x}_i ها (با فرض استقلال آزمایشها) مستقلند.

به طور کلی، متغیرهای تصادفی که مستقل و دارای توزیع یکسان باشند، (Independent Identically Distributed) i.i.d. نامیده می‌شوند.

اگر $\mathbf{x} = \begin{bmatrix} \mathbf{x}_1 \\ \vdots \\ \mathbf{x}_n \end{bmatrix}$ و \mathbf{x}_i ها i.i.d. باشند، داریم:

$$f_{\underline{\mathbf{x}}}(\underline{\mathbf{x}}) = f_{\mathbf{x}_1}(\mathbf{x}_1) \cdots f_{\mathbf{x}_n}(\mathbf{x}_n) = f_{\mathbf{x}}(\mathbf{x}_1) \cdots f_{\mathbf{x}}(\mathbf{x}_n)$$

استقلال

یکسان بودن توزیع

با نمونه‌برداری مکرر از یک متغیر تصادفی در یک جامعه (Population) (مثلاً جامعه پیچ‌ها در مثال بالا)، n متغیر تصادفی i.i.d. به دست می‌آیند. n را اندازه نمونه (Sample Size) می‌گویند.

چون x_i ها مستقلند، پس:

$$f_{x_i}(x) = f_x(x)$$

$$\Rightarrow E(x_i) = E(x) = \eta \quad \text{میانگین جامعه:}$$

$$\Rightarrow \text{var}(x_i) = \text{var}(x) = \sigma^2 \quad \text{واریانس جامعه:}$$

بحث نمونه برداری نقش اساسی در آمار دارد.

میانگین نمونه (Sample Mean):

طبق تعریف، برابر است با:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

داریم:

$$E(\bar{x}) = \frac{1}{n} \sum_{i=1}^n E(x_i) = \frac{1}{n} \cdot n\eta = \eta$$

$$\sigma_{\bar{x}}^2 = \frac{1}{n^2} \sum_{i=1}^n \sigma_{x_i}^2 = \frac{1}{n^2} \cdot n\sigma^2 = \frac{\sigma^2}{n}$$

پس هر چقدر n زیادتر شود، مقدار \bar{x} به η واقعی نزدیکتر خواهد بود. \bar{x} میانگین نمونه است، در حالی که η میانگین جامعه می‌باشد (پارامتر مدل مفروض).

با توجه به قضیه چبیشف داریم:

$$P\{|\bar{x} - \eta| < \varepsilon\} \geq 1 - \frac{\sigma_{\bar{x}}^2}{\varepsilon^2}$$

یعنی:

$$P\{|\bar{x} - \eta| < \varepsilon\} \geq 1 - \frac{\sigma^2}{n\varepsilon^2}$$

پس این احتمال با افزایش n به یک نزدیک می‌شود.

به همین ترتیب می‌توان در مورد واریانس نمونه بحث کرد که بعداً آن را خواهیم دید.

حال فرض کنید که یک آزمایش تصادفی را n بار انجام دهیم (x_i ها طبق تعریفی که داشتیم تعریف شده باشند) و مقادیر x_i در این آزمایشها ظاهر شوند ($i = 1, 2, \dots, n$). این اعداد را به ترتیب صعودی مرتب می‌کنیم:

$$x_{r_1} \leq x_{r_2} \leq \dots \leq x_{r_n}$$

اکنون نام مرتب شده آنها را y_i می‌نامیم، یعنی: $y_i = x_{r_i}$. پس خواهیم داشت:

$$y_1 \leq y_2 \leq \dots \leq y_n$$

مثلاً اگر اعداد x_i به ترتیب زیر به دست آمده باشند، داریم:

$$\begin{cases} x_1 = 12 \\ x_2 = 7 \\ x_3 = 13 \\ x_4 = 8 \\ x_5 = 9 \end{cases} \Rightarrow \begin{cases} y_1 = x_{r_1} = x_2 = 7 \\ y_2 = x_{r_2} = x_4 = 8 \\ y_3 = x_{r_3} = x_5 = 9 \\ y_4 = x_{r_4} = x_1 = 12 \\ y_5 = x_{r_5} = x_3 = 13 \end{cases}$$

متغیرهای تصادفی y_i را آماره‌های رتبه (آمارگان رتبه) x_i می‌نامند (آماره‌های رتبه کاربرد بسیاری در آشکارسازی و تخمین پارامتری دارند و در رادار و جنگ الکترونیک مورد استفاده قرار می‌گیرند).

آماره (Statistic):

طبق تعریف، تابعی از یک یا چند متغیر تصادفی را که به پارامتر نامعلومی بستگی نداشته باشند، آماره گویند. در بحث نمونه‌برداری،

تابعی از صرفاً بردار متغیرهای تصادفی نمونه $\underline{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$ را آماره گویند. مثلاً آماره رتبه یک نوع آماره است (زیرا تابعی از \underline{x} می‌باشد).

به عنوان حالت خاص برای y_1 و y_n داریم:

$$y_1 = \mathbf{x}_{\min} = \min(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$$

$$y_n = \mathbf{x}_{\max} = \max(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$$

پس:

$$\begin{aligned} F_{y_1}(y) &= P\{y_1 \leq y\} = P\{\mathbf{x}_{\min} \leq y\} = 1 - P\{\mathbf{x}_{\min} > y\} = 1 - P\{\mathbf{x}_1 > y, \mathbf{x}_2 > y, \dots, \mathbf{x}_n > y\} \\ &= 1 - P\{\mathbf{x}_1 > y\}P\{\mathbf{x}_2 > y\} \cdots P\{\mathbf{x}_n > y\} \\ &= 1 - [1 - F_x(y)]^n \end{aligned}$$

$$\Rightarrow f_{y_1}(y) = n[1 - F_x(y)]^{n-1} f_x(y)$$

$$\begin{aligned} F_{y_n}(y) &= P\{y_n \leq y\} = P\{\mathbf{x}_{\max} \leq y\} = P\{\mathbf{x}_1 \leq y, \mathbf{x}_2 \leq y, \dots, \mathbf{x}_n \leq y\} \\ &= P\{\mathbf{x}_1 \leq y\}P\{\mathbf{x}_2 \leq y\} \cdots P\{\mathbf{x}_n \leq y\} \\ &= [F_x(y)]^n \end{aligned}$$

$$\Rightarrow f_{y_n}(y) = n[F_x(y)]^{n-1} f_x(y)$$

(به کمک pdf نیز می‌توان روابط بالا را به دست آورد.)

در حالت کلی داریم:

$$f_{y_k}(y)dy = P\{y < y_k \leq y + dy\}$$

در صورتی این واقعه را خواهیم داشت که از n تا x_i ، $k-1$ تا کوچکتر از y ، $n-k$ تا بزرگتر از $y+dy$ و یکی بین y و $y+dy$ باشد.

یادآوری توزیع چندجمله‌ای: احتمال اینکه در n بار آزمایش، واقعه A_1 ، k_1 بار، واقعه A_2 ، k_2 بار و واقعه A_3 ، k_3 بار اتفاق افتد ($k_1 + k_2 + k_3 = n$ و $P(A_i) = p_i$) برابر است با:

$$p = \frac{n!}{k_1!k_2!k_3!} p_1^{k_1} p_2^{k_2} p_3^{k_3}$$

در نتیجه داریم:

$$f_{y_k}(y)dy = \frac{n!}{(k-1)!(n-k)!1!} [F_x(y)]^{k-1} [1-F_x(y+dy)]^{n-k} f_x(y)dy$$

$$dy \rightarrow 0 \Rightarrow f_{y_k}(y) = \frac{n!}{(k-1)!(n-k)!} [F_x(y)]^{k-1} [1-F_x(y)]^{n-k} f_x(y)$$

برای $k = 1$ ، توزیع x_{\min} و برای $k = n$ ، توزیع x_{\max} به دست می‌آید:

$$f_{x_{\min}}(y) = n[1 - F_x(y)]^{n-1} f_x(y) \quad , \quad 1 - F_{x_{\min}}(y) = [1 - F_x(y)]^n$$

$$f_{x_{\max}}(y) = n[F_x(y)]^{n-1} f_x(y) \quad , \quad F_{x_{\max}}(y) = [F_x(y)]^n$$

مجموع متغیرهای تصادفی مستقل:

می‌دانیم که اگر $z = x_1 + x_2$ بوده و x_1 و x_2 مستقل باشند، آنگاه داریم:

$$\Phi_z = \Phi_{x_1} \Phi_{x_2} \quad , \quad f_z = f_{x_1} * f_{x_2}$$

همچنین دیدیم که اگر $z = \sum_{i=1}^n x_i$ باشد، آنگاه:

$$\Phi_z(j\omega) = \Phi_{\underline{x}}(j\omega, \dots, j\omega)$$

و اگر x_i ها مستقل باشند، خواهیم داشت:

$$\Phi_z(j\omega) = \Phi_{x_1}(j\omega) \Phi_{x_2}(j\omega) \cdots \Phi_{x_n}(j\omega)$$

$$f_z = f_{x_1} * f_{x_2} * \cdots * f_{x_n}$$

(با توجه به اینکه عمل کانولوشن دارای خاصیت جابجایی و شرکت‌پذیری است.)

مثال: اگر \mathbf{x}_i ها مستقل بوده و هر یک دارای توزیع پواسن با پارامتر λ_i باشند، داریم:

$$\Phi_{\mathbf{z}}(j\omega) = \prod_{i=1}^n \Phi_{\mathbf{x}_i}(j\omega) = \prod_{i=1}^n e^{\lambda_i(e^{j\omega} - 1)} = e^{\lambda(e^{j\omega} - 1)}$$

که: $\lambda = \sum_{i=1}^n \lambda_i$ (یعنی مجموعشان هم دارای توزیع پواسن است، اما با پارامتر $\sum_{i=1}^n \lambda_i$).

اگر x_i ها i.i.d. باشند، یعنی: $\forall x: f_{x_1}(x) = f_{x_2}(x) = \dots = f_{x_n}(x) = f_x(x)$ ، در این صورت خواهیم داشت:

$$f_z = f_x * f_x * \dots * f_x$$

$$\Phi_z(\omega) = \Phi_x^n(\omega)$$

$$E(z) = nE(x)$$

$$\sigma_z^2 = n\sigma_x^2$$

مثال: اگر x_i ها مستقل بوده و همگی دارای توزیع نمایی باشند، یعنی: $f_{x_i}(x) = \lambda e^{-\lambda x} u(x)$ (یعنی i.i.d. باشند) و $z = \sum_{i=1}^n x_i$

باشد، آنگاه f_z چه خواهد بود؟ مثلاً اگر سیستمی از n المان به صورت Standby استفاده کند و خرابی این المان‌ها از هم مستقل باشد و برای همگی داشته باشیم: $f_x(x) = \lambda e^{-\lambda x} u(x)$ ، تابع چگالی عمر سیستم چه خواهد بود؟

$$\Phi_x(j\omega) = \frac{\lambda}{\lambda - j\omega} \Rightarrow \Phi_z(j\omega) = \left(\frac{\lambda}{\lambda - j\omega}\right)^n$$

با استفاده از جداول تبدیل فوریه داریم:

$$\frac{x^{n-1}}{(n-1)!} e^{-\lambda x} u(x) \xleftrightarrow{\mathfrak{F}} \frac{1}{(\lambda + j\omega)^n}$$

لذا:

$$f_z(z) = \lambda^n \frac{z^{n-1}}{(n-1)!} e^{-\lambda z} u(z)$$

که همان توزیع ارلانگ است (توزیع زمان لازم برای وقوع n واقعه کاملاً تصادفی یا به عبارتی مجموع n نمایی).

برای توزیع گاما $E(z) = \frac{r}{\lambda}$ است، در نتیجه داریم:

$$E(z) = \frac{n}{\lambda}$$

پس همان طور که انتظار داشتیم: $E(z) = n E(x)$ ؛ یعنی $MTTF$ ، n برابر شده است.

اگر این المان‌ها از نظر نقش در خرابی یا صحت سیستم به صورت موازی بودند، خواهیم داشت:

$$z = \max(x_1, \dots, x_n)$$

$$F_z(z) = F_x^n(z)$$

$$f_z(z) = n F_x^{n-1}(z) f_x(z)$$

برای $f_x(x) = \lambda e^{-\lambda x} u(x)$ می‌توانید نشان دهید که:

$$E(z) = \frac{1}{\lambda} \left(1 + \frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{n} \right)$$

مثلاً برای $n = 4$ ، مقدار $MTTF$ ، 2.1 برابر می‌شود.

در صورتی که این المان‌ها سری باشند، خواهیم داشت:

$$z = \min(x_1, \dots, x_n)$$

$$F_z(z) = 1 - (1 - F_x(z))^n = 1 - (e^{-\lambda z})^n$$

$$f_z(z) = n\lambda e^{-n\lambda z} u(z)$$

(توجه کنید که مقدار می‌نیمم تعدادی از متغیرهای تصادفی نمایی و i.i.d.، خود نیز نمایی است.)

پس:

$$E(z) = \frac{1}{n\lambda}$$

یعنی MTTF، $\frac{1}{n}$ برابر شده است.

مثال: اگر متغیر تصادفی \mathbf{x} به صورت زیر تعریف شود:

$$\mathbf{x}(\omega) = \begin{cases} 1 & \omega \in A \\ 0 & \text{otherwise} \end{cases}, \quad P(A) = p$$

مثلاً A واقعه آمدن شیر در پرتاب سکه باشد، \mathbf{x} دارای توزیع برنولی (دو جمله‌ای با $n = 1$) است. پس:

$$E(\mathbf{x}) = p, \quad \sigma_{\mathbf{x}}^2 = pq$$

حال با n بار تکرار این آزمایش (نمونه‌برداری از \mathbf{x}) و با فرض مستقل بودن آزمایش‌ها، \mathbf{x}_i های i.i.d. حاصل می‌شوند.

پس اگر تعریف کنیم:

$$\mathbf{z} = \mathbf{x}_1 + \mathbf{x}_2 + \dots + \mathbf{x}_n$$

\mathbf{z} تعداد شیرهای به دست آمده در n بار پرتاب سکه خواهد بود. یعنی:

$$\mathbf{z} \sim \text{Binomial}(n, p)$$

و خواهیم داشت:

$$E(\mathbf{z}) = nE(\mathbf{x}) = np$$

$$\sigma_{\mathbf{z}}^2 = n\sigma_{\mathbf{x}}^2 = npq$$

(می‌بینیم که این روش خیلی ساده‌تر از روش مستقیم و حتی خیلی ساده‌تر از روش تابع مشخصه است.)

مثال: متغیر تصادفی \mathbf{x} را برابر تعداد شکست‌ها تا حصول اولین موفقیت تعریف می‌کنیم. می‌دانیم که \mathbf{x} دارای توزیع هندسی است (توزیع دو جمله‌ای منفی با $r = 1$). در تمرین سری ۵ نشان دادید (از راه تابع مشخصه) که:

$$E(\mathbf{x}) = \frac{q}{p}, \quad \sigma_{\mathbf{x}}^2 = \frac{q}{p^2}, \quad \Phi_{\mathbf{x}}(j\omega) = \frac{p}{1 - qe^{j\omega}}$$

حال اگر تعریف کنیم:

$$\mathbf{z} = \mathbf{x}_1 + \mathbf{x}_2 + \dots + \mathbf{x}_r$$

که همه \mathbf{x}_i ها دارای توزیع هندسی بوده و مستقلند، آنگاه \mathbf{z} تعداد شکست‌ها تا حصول r امین موفقیت خواهد بود. یعنی:

$$\mathbf{z} \sim \text{Negative Binomial}(r, p)$$

پس:

$$E(\mathbf{z}) = \frac{rq}{p}, \quad \sigma_{\mathbf{z}}^2 = \frac{rq}{p^2}$$

در حالی که محاسبه این دو از راه مستقیم یا تابع مشخصه خیلی مشکلتر است.

همچنین در مورد $\Phi_{\mathbf{z}}(j\omega)$ داریم:

$$\Phi_{\mathbf{z}}(j\omega) = \left(\frac{p}{1 - qe^{j\omega}} \right)^r$$

در حالی که به دست آوردن مستقیم تابع مشخصه مشکلتر است.

قضیه حد مرکزی (Central Limit Theorem):

طبق قضیه حد مرکزی، اگر x_i ها مستقل بوده و $y = \sum_{i=1}^n x_i$ باشد، وقتی $n \rightarrow +\infty$ ، توزیع y به توزیع نرمال میل می کند (با شرایط سهلی)، ولو x_i ها نرمال نباشند. این در واقع بیانگر خاصیتی از کانولوشن است که کانولوشن تعداد زیادی توابع مثبت به گوسی میل می کند. با توجه به CLT معلوم می شود که چرا بسیاری از پدیده ها در جهان خارج توزیع تقریباً نرمال دارند. اصولاً هرگاه پدیده ای تحت تأثیر عوامل متعدد تصادفی باشد (قد یک فرد، خطا در اندازه گیری، ولتاژ نویز حرارتی و ...) تقریباً نرمال خواهد بود.

قضیه حد مرکزی لیاپانوف:

اگر $y = \sum_{i=1}^n x_i$ بوده و x_i ها مستقل باشند و $E(|x_i - \eta_i|^3) < +\infty$ (یا $E(|x_i|^3) < +\infty$) و $\sum_{i=1}^n \sigma_i^2 \xrightarrow{n \rightarrow +\infty} +\infty$ ، آنگاه برای $z = \frac{y - \eta_y}{\sigma_y}$ داریم:

$$F_z(z) \xrightarrow{n \rightarrow +\infty} G(z)$$

در قضیه لیاپانوف لزوماً توزیع x_i ها یکسان نیست (لزوماً i.i.d. نیستند). صورت دیگری از قضیه حد مرکزی داریم که صرفاً برای x_i های i.i.d. است.

قضیه حد مرکزی لیندبرگ - لوی:

اگر $y = \sum_{i=1}^n x_i$ بوده و x_i ها i.i.d. با واریانس محدود $\sigma^2 < +\infty$ باشند، آنگاه برای $z = \frac{y - \eta_y}{\sigma_y}$ داریم:

$$F_z(z) \xrightarrow{n \rightarrow +\infty} G(z)$$

قضیه لیندبرگ-لوی حالت خاصی از قضیه لیاپانوف نمی‌باشد. چون در اینجا دیگر شرط $E[(x_i - \eta_i)^3] < +\infty$ لازم نیست و

شرط ضعیفتر $\sigma^2 < +\infty$ جایگزین آن شده است (شرط دیگر قضیه لیاپانوف، یعنی $\sum_{i=1}^n \sigma_i^2 \xrightarrow{n \rightarrow +\infty} +\infty$ ، مسلماً

ارضاء می‌شود).

همچنین قضیه لیندبرگ-فلر را داریم که برای حالت کلی (x_i های نه لزوماً i.i.d.) شرط لازم و کافی گوسی بودن توزیع حدی را ارائه می‌کند که تعبیر با تسامحش این است که $\forall j: \lim_{n \rightarrow +\infty} \frac{\sigma_j^2}{\sum_{i=1}^n \sigma_i^2} = 0$. یعنی هیچ جمله‌ای غالب نباشد و در مورد همه جمله‌ها، واریانس آن در مقابل واریانس کل ناچیز باشد. توجه کنید که برقراری شرایط قضیه لیاپانوف، برقراری شرایط قضیه لیندبرگ-فلر را نتیجه می‌دهد.

وقتی n بی‌نهایت نبوده ولی بزرگ باشد هم می‌توانیم نرمال را به عنوان تقریب به کار ببریم. اگر توزیع x هموار باشد، حتی برای $n=5$ ، بسیار به توزیع نرمال نزدیک خواهیم بود. در اغلب کاربردها $n=30$ کاملاً کافی است (در کتاب، $n=3$ را برای توزیع یکنواخت به کار برده و با نرمال مقایسه کرده است).

مثال: جعبه ای شامل ۱۰۰ مقاومت $1\text{k}\Omega \pm 5\%$ در اختیار داریم. اگر توزیع مقدار مقاومت‌ها را یکنواخت فرض کنیم، احتمال اینکه مجموع مقدار این مقاومت‌ها در محدوده $100\text{k}\Omega \pm 0.5\%$ باشد، چیست؟

$$y = \sum_{i=1}^{100} x_i$$

$$\sigma_x^2 = \frac{(b-a)^2}{12} = \frac{(100)^2}{12} < +\infty$$

پس شرط قضیه لیندبرگ-لوی برقرار است (اگر توزیع را نمی‌دانستیم و فقط همین واریانس را می‌دانستیم هم کافی بود).

$$E(\mathbf{x}) = 1000 \Rightarrow E(\mathbf{y}) = 100000$$

$$\sigma_y^2 = n\sigma_x^2 = 100 \frac{(100)^2}{12} = \frac{10^6}{12}$$

$$P\{99500 < \mathbf{y} < 100500\} = G\left(\frac{100500 - 100000}{\sqrt{\frac{10^6}{12}}}\right) - G\left(\frac{99500 - 100000}{\sqrt{\frac{10^6}{12}}}\right) = 2G(1.732) - 1 = 0.917$$

در بیان قضیه‌های فوق از تابع توزیع انباشته استفاده شد تا برای حالت گسسته هم صادق باشد. چون در حالت گسسته، تابع چگالی یک سری δ است و نرمال که پیوسته است، نمی‌تواند آن را تقریب بزند (اگر چه نرمال، پوش مقدار وزنه این δ ها را تقریب می‌زند).

به عنوان مثال قضیه دموار-لاپلاس حالت خاصی از CLT است.

مثال: x_i ها متغیرهای تصادفی i.i.d. و دارای توزیع برنولی هستند، یعنی:

$$P\{x_i = 1\} = p, \quad P\{x_i = 0\} = q = 1 - p$$

حال اگر تعریف کنیم:

$$y = \sum_{i=1}^n x_i$$

y دارای توزیع دو جمله‌ای است، یعنی:

$$P\{y = k\} = \binom{n}{k} p^k q^{n-k}$$

چون x_i ها i.i.d. هستند و $\sigma_x^2 = pq < +\infty$ ، پس طبق قضیه لیندبرگ-لوی تابع توزیع y توسط نرمال قابل تقریب است (برای $n \rightarrow \infty$ به نرمال میل می‌کند). یعنی قضیه دموار-لاپلاس را می‌توان حالت خاصی از CLT دانست.

اثبات قضیه حد مرکزی در حالت i.i.d. بودن \mathbf{x}_i ها و محدود بودن تمامی گشتاورها:

$$\mathbf{y} = \sum_{i=1}^n \mathbf{x}_i \Rightarrow \eta_{\mathbf{y}} = n\eta, \quad \sigma_{\mathbf{y}}^2 = n\sigma^2$$

$$\mathbf{z} = \frac{\mathbf{y} - \eta_{\mathbf{y}}}{\sigma_{\mathbf{y}}} = \frac{\sum_{i=1}^n (\mathbf{x}_i - \eta)}{\sqrt{n}\sigma} = \frac{1}{\sqrt{n}} \sum_{i=1}^n \underbrace{\left(\frac{\mathbf{x}_i - \eta}{\sigma} \right)}_{\mathbf{u}_i} \quad \mathbf{v}$$

$$\Phi_{\mathbf{z}}(j\omega) = E(e^{j\omega\mathbf{z}}) = E(e^{\frac{j\omega}{\sqrt{n}}\mathbf{v}}) = \Phi_{\mathbf{v}}\left(\frac{j\omega}{\sqrt{n}}\right)$$

اگر فرض کنیم $\mathbf{u}_i \triangleq \frac{\mathbf{x}_i - \eta}{\sigma}$ ، چون $\mathbf{v} = \sum_{i=1}^n \mathbf{u}_i$ و \mathbf{u}_i ها i.i.d. هستند، پس:

$$\Phi_{\mathbf{v}}(j\omega) = \Phi_{\mathbf{u}}^n(j\omega) \Rightarrow \Phi_{\mathbf{z}}(j\omega) = \Phi_{\mathbf{u}}^n\left(\frac{j\omega}{\sqrt{n}}\right)$$

اما اگر تابع مشخصه را بسط تیلور دهیم، خواهیم داشت:

$$\Phi(j\omega) = 1 + j\omega\Phi'(0) + \frac{(j\omega)^2}{2}\Phi''(0) + \frac{(j\omega)^3}{3!}\Phi'''(0) + \dots$$

که: $\Phi^{(n)}(0) = m_n$.

پس در مورد \mathbf{u} داریم:

$$\Phi'(0) = \eta_{\mathbf{u}} = 0 \quad , \quad \Phi''(0) = \sigma_{\mathbf{u}}^2 = 1 \quad , \quad \Phi'''(0) = m_3(\mathbf{u}) = E\left[\left(\frac{\mathbf{x}_i - \eta}{\sigma}\right)^3\right]$$

در نتیجه:

$$\Phi_{\mathbf{u}}(j\omega) = 1 + \frac{(j\omega)^2}{2} + \frac{(j\omega)^3}{3!}\Phi'''(0) + \dots \Rightarrow \Phi_{\mathbf{z}}(j\omega) = \left[1 + \frac{(j\omega)^2}{2n} + \frac{(j\omega)^3}{3!n^{\frac{3}{2}}}\Phi'''(0) + \dots \right]^n$$

می‌دانیم که اگر $\lim_{n \rightarrow +\infty} a_n = b$ ، آنگاه:

$$\lim_{n \rightarrow +\infty} \left(1 + \frac{a_n}{n} \right)^n = e^b$$

(یا با توجه به $\ln(1+x) = x - \frac{x^2}{2} + \frac{x^3}{3} \mp \dots$)

پس:

$$\Phi_z(j\omega) = \left[1 + \frac{(j\omega)^2}{2n} + \frac{(j\omega)^3}{3!n^{\frac{3}{2}}} \Phi'''(0) + \dots \right]^n$$

$$\rightarrow a_n = 1 + \frac{(j\omega)^2}{2} + \frac{(j\omega)^3}{3!n^{\frac{1}{2}}} \Phi'''(0) + \dots \Rightarrow \lim_{n \rightarrow +\infty} \Phi_z(j\omega) = e^{-\frac{\omega^2}{2}}$$

که تابع مشخصه نرمال استاندارد است (قضیه‌ای داریم که اگر $\Phi_n \rightarrow \Phi^*$ ، آنگاه $F_n \rightarrow F^*$).

همگرایی دنباله متغیرهای تصادفی:

می‌دانیم که: $x_1, x_2, \dots, x_n, \dots$ یک دنباله از اعداد است و همگرایی این دنباله به عدد a ، یعنی برای هر $\varepsilon > 0$ ، n_0 ای وجود داشته باشد که:

$$|x_n - a| < \varepsilon : n > n_0$$

در این صورت می‌نویسیم:

$$\lim_{n \rightarrow +\infty} x_n = a$$


حال در مورد متغیرهای تصادفی مفهوم همگرایی به چه صورت خواهد بود؟

تعریف فرآیند تصادفی (Random Process or Stochastic Process):

دنباله نامحدود $x_1, x_2, \dots, x_n, \dots$ از متغیرهای تصادفی را فرآیند تصادفی گویند.

توجه دارید که هر x_i تابعی از نقاط فضای نمونه است، یعنی برای هر نقطه ω_i یک دنباله عددی به صورت زیر داریم:

$$x_1(\omega_i), x_2(\omega_i), \dots, x_n(\omega_i), \dots$$



توجه داشته باشید که:


$x_n(\omega)$: فرآیند تصادفی :

$x_n(\omega_i)$: دنباله عددی :

$x_{n_0}(\omega)$: متغیر تصادفی :

$x_{n_0}(\omega_i)$: یک عدد :

آنچه گفتیم فرآیند تصادفی گسسته بود (سیگنال گسسته در زمان). به طور مشابه می‌توانیم فرآیند تصادفی پیوسته $x_t(\omega)$ را تعریف کنیم.



مثال: شیر یا خط می‌اندزیم. اگر شیر آمد، سیگنال سینوسی و اگر خط آمد سیگنال مربعی می‌فرستیم، یعنی به احتمال $\frac{1}{2}$ سینوسی و به احتمال $\frac{1}{2}$ مربعی.

مثال: برای نویز روی مقاومت، مقدار ولتاژ نویز در یک لحظه، متغیر تصادفی است. ولی شکل موج روی آن در یک مدت زمانی، فرآیند تصادفی است.

در مورد همگرایی دنباله متغیرهای تصادفی ممکن است $\mathbf{x}_n(\omega)$ برای بعضی ω ها همگرا باشد و برای بعضی دیگر نباشد. یک تعریف برای همگرایی دنباله متغیر تصادفی می‌تواند این باشد که کلیه دنباله‌های نمونه، یعنی $\mathbf{x}_n(\omega)$ برای هر ω همگرا باشد (everywhere). ولی در بسیاری موارد ممکن است این طور نباشد و همگرایی ضعیف‌تری داشته باشیم.

۱. همگرایی تقریباً همه جا (Almost Everywhere):

به این نوع همگرایی، همگرایی a.e. همگرایی به احتمال یک و نیز همگرایی Almost Sure گفته می‌شود. $\mathbf{x}_n(\omega)$ ممکن است برای بعضی ω ها حد داشته و برای بعضی دیگر حد نداشته باشد. اگر مجموعه ω هایی که برای آنها $\mathbf{x}_n(\omega)$ حد ندارد احتمالش صفر باشد، یعنی:

$$P\{\omega : \mathbf{x}_n(\omega) \xrightarrow{n \rightarrow +\infty} \mathbf{x}\} = 1$$

گوییم \mathbf{x}_n دارای همگرایی a.e. است. در حالت کلی \mathbf{x} می‌تواند تابع ω باشد (یعنی عدد ثابتی نباشد، بلکه متغیر تصادفی باشد). در این صورت می‌نویسیم:

$$\mathbf{x}_n \xrightarrow[n \rightarrow +\infty]{\text{a.e.}} \mathbf{x}$$

۲. همگرایی در احتمال:

یعنی برای هر $\varepsilon > 0$ داشته باشیم:

$$P\{|\mathbf{x}_n - \mathbf{x}| \geq \varepsilon\} \xrightarrow{n \rightarrow +\infty} 0$$

اگر $\mathbf{x} = c$ ، یعنی عددی ثابت باشد، این به آن معناست که توزیع \mathbf{x}_n با افزایش n حول c متمرکزتر می‌شود. در این صورت می‌نویسیم:

$$\mathbf{x}_n \xrightarrow[n \rightarrow +\infty]{P} \mathbf{x}$$

یا:

$$P \lim_{n \rightarrow +\infty} \mathbf{x}_n = \mathbf{x}$$

روشن است که همگرایی به احتمال یک، همگرایی در احتمال را نتیجه می‌دهد.

۳. همگرایی به مفهوم (Mean Square) m.s. (همگرایی در گشتاور دوم):

برای هر n ، $\mathbf{x}_n - \mathbf{x}$ یک متغیر تصادفی است و گشتاور دوم آن $E[(\mathbf{x}_n - \mathbf{x})^2]$ می باشد. پس $E[(\mathbf{x}_n - \mathbf{x})^2]$ یک دنباله عددی است.

می گوییم \mathbf{x}_n به \mathbf{x} به مفهوم m.s. میل می کند و می نویسیم: $\mathbf{x}_n \xrightarrow[n \rightarrow +\infty]{\text{m.s.}} \mathbf{x}$ هر گاه:

$$E[(\mathbf{x}_n - \mathbf{x})^2] \xrightarrow[n \rightarrow +\infty]{} 0$$

همگرایی به مفهوم m.s. همگرایی در احتمال را نتیجه می دهد.

زیرا با توجه به نامساوی Bienayme (به ازای $a = 2$) داریم:

$$P\{|\mathbf{x}_n - \mathbf{x}| > \varepsilon\} \leq \frac{E[(\mathbf{x}_n - \mathbf{x})^2]}{\varepsilon^2}$$

پس وقتی $E[(\mathbf{x}_n - \mathbf{x})^2]$ به سمت صفر میل می کند، این احتمال هم به صفر میل می کند.

پس همگرایی m.s. و همگرایی به احتمال یک (a.e.) قویتر از همگرایی در احتمالند.

۴. همگرایی در تابع توزیع:

x_n را همگرا به x در تابع توزیع گویند، هرگاه برای هر x (هر x ای که $F_x(x)$ پیوسته باشد) داشته باشیم:

$$F_{x_n}(x) \xrightarrow{n \rightarrow +\infty} F_x(x)$$

این ضعیف‌ترین نوع همگرایی است. CLT نمونه‌ای از همگرایی در تابع توزیع بود.

قانون اعداد بزرگ:

در فصل ۳ دیدیم که اگر در یک آزمایش تصادفی $P(A) = p$ باشد و در n بار تکرار آزمایش، k بار واقعه A اتفاق افتد، احتمال اینکه $\frac{k}{n}$ بین $p - \varepsilon$ و $p + \varepsilon$ باشد، وقتی $n \rightarrow +\infty$ به سمت یک می‌رود، یعنی:

$$P\left\{\left|\frac{k}{n} - p\right| \leq \varepsilon\right\} \rightarrow 1 \quad \text{برای هر } \varepsilon > 0 \text{ داده شده}$$

حال در حالت کلی‌تر داریم:

قانون ضعیف اعداد بزرگ (Weak Law of Large Numbers):

اگر x_i ها نمونه‌های تصادفی از جامعه‌ای با میانگین η و i.i.d. باشند و $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ میانگین نمونه باشد، داریم:

$$\text{Plim}_{n \rightarrow +\infty} \bar{x}_n = \eta \quad \text{یا} \quad \bar{x}_n \xrightarrow[n \rightarrow +\infty]{P} \eta$$

یعنی:

$$P\{|\bar{x}_n - \eta| > \varepsilon\} \xrightarrow[n \rightarrow +\infty]{} 0$$

اثبات: می‌دانیم که:

$$E(\bar{x}) = \eta \quad , \quad \sigma_{\bar{x}}^2 = \frac{\sigma^2}{n}$$

لذا با توجه به قضیهٔ چبیشف خواهیم داشت:

$$P\{|\bar{x} - \eta| > \varepsilon\} < \frac{\sigma^2}{n\varepsilon^2} \xrightarrow[n \rightarrow +\infty]{} 0$$

یا می‌توانیم بگوییم که:

$$E[(\bar{x}_n - \eta)^2] = \sigma_{\bar{x}_n}^2 = \frac{\sigma^2}{n} \xrightarrow{n \rightarrow +\infty} 0$$

پس:

$$\bar{x}_n \xrightarrow[n \rightarrow +\infty]{\text{m.s.}} \eta$$

در نتیجه:

$$\bar{x}_n \xrightarrow[n \rightarrow +\infty]{P} \eta$$

قانون قوی اعداد بزرگ (Strong Law of Large Numbers):

اگر x_i ها متغیرهای تصادفی i.i.d. باشند و $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ باشد، \bar{x}_n با احتمال یک به η میل می‌کند.


$$\bar{x}_n \xrightarrow[n \rightarrow +\infty]{\text{a.e.}} \eta$$

توابع توزیع متداول در آمار:

توزیع χ^2 : این توزیع کاربرد زیادی در آمار دارد. بنا بر تعریف، توزیع χ^2 با m درجه آزادی برابر است با:

$$x \sim \chi^2(m) = \text{Gamma}(r = \frac{m}{2}, \lambda = \frac{1}{2})$$

$$f_x(x) = \frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} x^{\frac{m}{2}-1} e^{-\frac{x}{2}} u(x)$$



به ازای $m = 2$ ، این توزیع همان توزیع نمایی می‌شود.

داریم:

$$\Gamma\left(\frac{m}{2}\right) = \begin{cases} (k-1)! & m = 2k \\ \left(k - \frac{1}{2}\right)\left(k - \frac{3}{2}\right) \cdots \frac{1}{2} \sqrt{\pi} & m = 2k + 1 \end{cases} \quad \left(\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi} \text{ چون}\right)$$

قبلاً گشتاور مرتبه n م توزیع گاما را به دست آورده بودیم:

$$m_n = \frac{\Gamma(n+r)}{\Gamma(r)\lambda^n}$$

پس برای توزیع χ^2 داریم:

$$E(\mathbf{x}^n) = \frac{\Gamma(n + \frac{m}{2})}{\Gamma(\frac{m}{2}) (\frac{1}{2})^n}$$

پس خواهیم داشت:

$$E(\mathbf{x}) = m \quad , \quad E(\mathbf{x}^2) = m(m+2) \quad \Rightarrow \quad \text{var}(\mathbf{x}) = 2m$$

رابطه $m_n = \frac{\Gamma(n + \frac{m}{2})}{\Gamma(\frac{m}{2}) (\frac{1}{2})^n}$ حتی برای n منفی صادق است (مشروط بر اینکه $n + \frac{m}{2} > 0$ باشد). مثلاً داریم:

$$E\left(\frac{1}{\mathbf{x}}\right) = \frac{\Gamma(\frac{m}{2} - 1)}{2\Gamma(\frac{m}{2})} = \frac{1}{2(\frac{m}{2} - 1)} = \frac{1}{m-2} : m > 2$$

تابع مشخصه توزیع گاما را نیز قبلاً به دست آورده بودیم (در تمرین سری ۵):

$$\Phi(j\omega) = \left(\frac{\lambda}{\lambda - j\omega} \right)^r$$

پس برای توزیع χ^2 داریم:

$$\Phi_x(j\omega) = \left(\frac{\frac{1}{2}}{\frac{1}{2} - j\omega} \right)^{\frac{m}{2}} = \frac{1}{(1 - 2j\omega)^{\frac{m}{2}}}$$

قضیه: اگر متغیرهای تصادفی x_1, x_2, \dots, x_n مستقل باشند و $x_i \sim \chi^2(k_i)$ بوده و $z = \sum_{i=1}^n x_i$ باشد، در این صورت داریم:

$$z \sim \chi^2\left(\sum_{i=1}^n k_i\right)$$

در تمرین سری هشتم این قضیه را برای توزیع گاما دیدیم. پس برای توزیع χ^2 نیز که حالت خاصی از توزیع گاما است نیز صادق می‌باشد $(\lambda = \frac{1}{2})$.

قضیه خاصیت اساسی توزیع χ^2 : اگر متغیرهای تصادفی x_1, x_2, \dots, x_n مستقل و نرمال استاندارد باشند و $Q = \sum_{i=1}^n x_i^2$ باشد،

در این صورت داریم:

$$Q \sim \chi^2(n)$$

اثبات:

$$\begin{cases} y_i = x_i^2 \\ x_i \sim N(0,1) \end{cases} \Rightarrow f_{y_i}(y) = \frac{1}{\sqrt{y}} e^{-\frac{y}{2}} : y > 0 \Rightarrow y_i \sim \chi^2(1)$$

پس طبق قضیه قبل چون: $Q = \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i$ داریم:

$$Q \sim \chi^2(n)$$

(به طور مستقیم هم می توان نشان داد، ولی قدری مشکل است. اثبات در کتاب فرآیند Papoulis، صفحه ۲۵۱).

قضیه: اگر متغیرهای تصادفی x_1, x_2, \dots, x_n مستقل و نرمال استاندارد باشند، فرم درجه دوم $Q = \underline{x}^T A \underline{x} = \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j$

(که در آن A یک ماتریس متقارن $n \times n$ است) دارای توزیع $\chi^2(r)$ خواهد بود، اگر و تنها اگر r مقدار ویژه ماتریس A برابر یک و سایر $n - r$ مقدار ویژه آن برابر صفر باشند.

اثبات: از جبر خطی می‌دانیم که ماتریس A را می‌توان به صورت زیر نوشت:

$$A = U \Lambda U^{-1} = U \Lambda U^T$$

که در آن:

$$U = [\underline{u}_1 \quad \underline{u}_2 \quad \cdots \quad \underline{u}_n] \quad , \quad \Lambda = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \lambda_n \end{bmatrix}$$

زیرا از تعریف بردار ویژه و مقدار ویژه داریم:

$$A \underline{u}_i = \lambda_i \underline{u}_i$$

$$\Rightarrow [A\underline{u}_1 \quad A\underline{u}_2 \quad \cdots \quad A\underline{u}_n] = [\lambda_1\underline{u}_1 \quad \lambda_2\underline{u}_2 \quad \cdots \quad \lambda_n\underline{u}_n]$$

$$\Rightarrow A[\underline{u}_1 \quad \underline{u}_2 \quad \cdots \quad \underline{u}_n] = [\underline{u}_1 \quad \underline{u}_2 \quad \cdots \quad \underline{u}_n] \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \lambda_n \end{bmatrix}$$

$$\Rightarrow AU = U\Lambda \Rightarrow A = U\Lambda U^{-1}$$

البته اگر A متقارن باشد، U ماتریس Unitary خواهد بود، یعنی: $U^{-1} = U^T$. زیرا:

$$\underline{u}_i \cdot \underline{u}_j^T = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases}$$

به عبارت دیگر:

$$\Lambda = U^T A U$$

اگر تعریف کنیم:

$$\underline{z} = U^T \underline{x} \Rightarrow \underline{x} = U \underline{z}$$

$$E(\underline{z}) = U^T E(\underline{x}) = 0$$

$$C_{\underline{z}} = U^T C_{\underline{x}} U = U^T I U = U^T U = I$$

یعنی z_i ها نرمال استاندارد و مستقل هستند.

$$Q = \underline{x}^T A \underline{x} = \underline{z}^T U^T A U \underline{z} = \underline{z}^T \Lambda \underline{z} = \sum_{i=1}^n \lambda_i z_i^2$$

پس Q توزیع $\chi^2(r)$ خواهد داشت، اگر و تنها اگر λ_i ها صرفاً صفر یا یک باشند (r تعداد مقادیر ویژه غیر صفر ($\lambda = 1$) است).

قضیه: اگر برای سه فرم درجه دوم Q_1 ، Q_2 و Q_3 داشته باشیم: $Q_3 = Q_2 - Q_1$ که: $Q_1 \sim \chi^2(r)$ ، $Q_2 \sim \chi^2(n)$ و $Q_3 \geq 0$ باشند، آنگاه Q_1 و Q_3 مستقلند و $Q_3 \sim \chi^2(n-r)$ است.

از کاربردهای مهم توزیع χ^2 در بررسی واریانس نمونه از توزیع نرمال است.

واریانس نمونه:

قبلاً دیدیم که میانگین نمونه برابر است با:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \rightarrow E(\bar{x}) = \eta, \quad \sigma_{\bar{x}}^2 = \frac{\sigma^2}{n}$$

طبق تعریف، واریانس نمونه برابر است با:

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

در تمرین (سری هشتم) نشان دادید که:

$$E[(x_i - \bar{x})^2] = \frac{n-1}{n} \sigma^2$$

$$E(s^2) = \frac{1}{n} \cdot n \left(\frac{n-1}{n} \sigma^2 \right) = \frac{n-1}{n} \sigma^2$$

پس:

یعنی s^2 تخمینی نااریب از σ^2 نیست. البته اگر η را می دانستیم، تخمینی نااریب از σ^2 می شد، زیرا:

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \eta)^2 \rightarrow E(s^2) = \frac{1}{n} \cdot n \sigma^2 = \sigma^2$$

ولی وقتی η و σ^2 هیچکدام معلوم نیستند، معمولاً از تخمین زیر استفاده می شود که نااریب است (اگر چه بعداً خواهیم دید که واریانس این تخمین قدری بیشتر است):

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 : \text{واریانس نمونه}$$

(بعضاً این تعریف را با s_{n-1}^2 و تعریف اولی را با s_n^2 نشان می دهند. برای n بزرگ، این دو تعریف یکسان می شوند. برای n کوچک معمولاً از تعریف دومی استفاده می شود.)

با این تعریف خواهیم داشت:

$$E(s^2) = \frac{1}{n-1} \cdot n \cdot \frac{n-1}{n} \sigma^2 = \sigma^2$$

قضیه: میانگین نمونه و واریانس نمونه یک متغیر تصادفی نرمال، مستقل از هم هستند و داریم:

$$\frac{(n-1)s^2}{\sigma^2} = \frac{n\mathcal{Y}^2}{\sigma^2} \sim \chi^2(n-1)$$

اثبات:

$$\frac{(n-1)s^2}{\sigma^2} = \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{\sigma} \right)^2 = \underbrace{\sum_{i=1}^n \left(\frac{x_i - \eta}{\sigma} \right)^2}_{Q_2} - \underbrace{\left(\frac{\bar{x} - \eta}{\frac{\sigma}{\sqrt{n}}} \right)^2}_{Q_1} \rightarrow Q_2 \sim \chi^2(n), Q_1 \sim \chi^2(1)$$

پس با توجه به قضیه قبلی، $Q_3 = Q_2 - Q_1$ دارای توزیع $\chi^2(n-1)$ است، یعنی:

$$\frac{(n-1)s^2}{\sigma^2} \sim \chi^2(n-1)$$

و نیز Q_1 و Q_3 مستقلند. در نتیجه میانگین نمونه (\bar{x}) و واریانس نمونه (\mathcal{Y}^2 یا s^2) مستقلند.

حال که فهمیدیم $\frac{(n-1)s^2}{\sigma^2} = \frac{n\mathcal{E}^2}{\sigma^2} \sim \chi^2(n-1)$ است و می‌دانیم که واریانس متغیر تصادفی $\chi^2(m)$ ، $2m$ است، داریم:

$$\text{var}(s^2) = \left(\frac{\sigma^2}{n-1} \right)^2 \cdot 2(n-1) = \frac{2\sigma^4}{n-1}$$

$$\text{var}(\mathcal{E}^2) = \left(\frac{\sigma^2}{n} \right)^2 \cdot 2(n-1) = \frac{2(n-1)}{n^2} \sigma^4$$

(یعنی s^2 اگر چه نااریب است، ولی واریانس بیشتری دارد. همچنین ملاحظه می‌کنید که وقتی $n \rightarrow +\infty$ ، واریانس به سمت صفر می‌رود.)

توزیع χ^2 غیر مرکزی (Noncentral χ^2 Distribution):

اگر \mathbf{x}_i ها به جای اینکه $N(0,1)$ باشند، $N(\eta_i,1)$ بوده و مستقل نیز باشند، $\mathbf{Q} = \sum_{i=1}^n \mathbf{x}_i^2$ دیگر توزیع χ^2 ندارد، بلکه توزیع آن χ^2 غیر مرکزی است:

$\mathbf{Q} \sim \chi^2(n, e) \rightarrow$ n : درجه آزادی / e : خروج از مرکز (Eccentricity)

$$e = \sum_{i=1}^n \eta_i^2, \quad E(\mathbf{Q}) = n + e$$

همچنین اگر $\mathbf{x}_i \sim N(\eta_i, 1)$ ، $\mathbf{Q} = \mathbf{x}^T \mathbf{A} \mathbf{x}$ و ماتریس \mathbf{A} دارای r مقدار ویژه یک و $n-r$ مقدار ویژه صفر باشد، آنگاه $\mathbf{Q} \sim \chi^2(r, e)$ خواهد بود که:

$$e = \underline{\eta}_{\mathbf{x}}^T \mathbf{A} \underline{\eta}_{\mathbf{x}}$$

اثبات در کتاب، صفحات ۲۲۷ و ۲۲۸.


توزیع t (Student t):

Gosset در سال ۱۹۰۸ تحت نام مستعار Student این توزیع را معرفی کرد:

$x \sim t(m) \rightarrow$ m : درجه آزادی

$$f_x(x) = \gamma \frac{1}{\left(1 + \frac{x^2}{m}\right)^{\frac{m+1}{2}}} \rightarrow \gamma = \frac{\Gamma\left(\frac{m+1}{2}\right)}{\sqrt{\pi m} \Gamma\left(\frac{m}{2}\right)}$$

این توزیع برای $m = 1$ همان توزیع کوشی است و برای $n \rightarrow +\infty$ می‌توان نشان داد که توزیع نرمال می‌شود. یعنی هر چه m کوچکتر باشد، دُم pdf درازتر است.



برای توزیع $t(n)$ ، m_k برای $k \geq n$ وجود ندارد، چون $E(|\mathbf{x}|^k)$ نامحدود می‌شود. مثلاً دیده بودیم که در توزیع کوشی، $E(\mathbf{x})$ نداریم. پس داریم:

$$E(\mathbf{x}) = 0 : m > 1$$

$$E(\mathbf{x}^2) = \text{var}(\mathbf{x}) = \frac{m}{m-2} : m > 2$$

قضیه خاصیت اساسی توزیع t : اگر $z \sim N(0,1)$ و $w \sim \chi^2(m)$ بوده و z و w مستقل باشند، در این صورت $x = \frac{z}{\sqrt{\frac{w}{m}}}$

دارای توزیع $t(m)$ خواهد بود، یعنی:

$$x \sim t(m)$$

برای اثبات، مثلاً به روش متغیر کمکی می‌توانیم از روی f_{zw} ، f_x را به دست آوریم ($y = w$ و $x = \frac{z}{\sqrt{\frac{w}{m}}}$).

اثبات در کتاب، صفحه ۲۳۳.

ضمناً اگر $z \sim N(e,1)$ باشد، $x \sim t(m,e)$ خواهد بود، یعنی توزیع t غیرمرکزی (Noncentral t Distribution) با m درجه آزادی و خروج از مرکز e خواهد داشت.

با توجه به قضیه فوق برای توزیع t داریم:

$$E(\mathbf{x}^2) = m \cdot E(\mathbf{z}^2)E\left(\frac{1}{\mathbf{w}}\right) = m \cdot 1 \cdot \frac{1}{m-2} = \frac{m}{m-2}$$

همچنین داریم:

$$t(m) \xrightarrow{m \rightarrow +\infty} N(0,1)$$

زیرا اگر $\mathbf{x} = \frac{\mathbf{z}}{\sqrt{\frac{\mathbf{w}}{m}}}$ باشد که $\mathbf{z} \sim N(0,1)$ و $\mathbf{w} \sim \chi^2(m)$ هستند، در مورد متغیر تصادفی \mathbf{w} که دارای توزیع $\chi^2(m)$ است، خواهیم داشت:

$$\begin{cases} E(\mathbf{w}) = m \\ \text{var}(\mathbf{w}) = 2m \end{cases} \Rightarrow \begin{cases} E\left(\frac{\mathbf{w}}{m}\right) = 1 \\ \text{var}\left(\frac{\mathbf{w}}{m}\right) = \frac{2}{m} \end{cases}$$

پس: $\frac{\mathbf{w}}{m} \xrightarrow{m \rightarrow +\infty} 1$ m.s. یعنی: $\mathbf{x} \rightarrow \mathbf{z}$.

برای m های کمتر ($m > 20$) داریم:

$$\mathbf{x} \approx \mathbf{z} \sqrt{\frac{m}{m-2}}$$

$$\text{زیرا: } E(\mathbf{x}^2) = \frac{m}{m-2}, \text{ ولی: } E(\mathbf{z}^2) = 1.$$

کاربرد توزیع t : اگر $\bar{\mathbf{x}}$ و \mathbf{s}^2 میانگین و واریانس نمونه از متغیرهای تصادفی نرمال $N(\eta, \sigma)$ باشند و داشته باشیم:

$$\mathbf{T} = \frac{\bar{\mathbf{x}} - \eta}{\frac{\mathbf{s}}{\sqrt{n}}}$$

در این صورت داریم:

$$\mathbf{T} \sim t(n-1)$$

(در حالی که می دانیم $\frac{\bar{\mathbf{x}} - \eta}{\frac{\sigma}{\sqrt{n}}}$ دارای توزیع نرمال استاندارد است.)

اثبات: با توجه به قضیه‌ای که داشتیم، $\mathbf{z} = \frac{\bar{\mathbf{x}} - \eta}{\frac{\sigma}{\sqrt{n}}}$ و $\mathbf{w} = (n-1) \frac{\mathbf{s}^2}{\sigma^2}$ مستقلند و $\mathbf{z} \sim N(0,1)$ و $\mathbf{w} \sim \chi^2(n-1)$ هستند.

پس طبق قضیه بالا خواهیم داشت:

$$\mathbf{T} = \frac{\bar{\mathbf{x}} - \eta}{\frac{\mathbf{s}}{\sqrt{n}}} = \frac{\frac{\bar{\mathbf{x}} - \eta}{\frac{\sigma}{\sqrt{n}}}}{\sqrt{\frac{(n-1) \frac{\mathbf{s}^2}{\sigma^2}}{n-1}}} = \frac{\mathbf{z}}{\sqrt{\frac{\mathbf{w}}{n-1}}} \sim t(n-1)$$

توجه کنید که مقدار \mathbf{T} و توزیع آن ربطی به σ^2 پروسه نرمال مورد نمونه‌گیری ندارد.

نکته دیگر اینکه برای $n \rightarrow +\infty$ که تخمین \mathbf{s} از σ بهتر و بهتر می‌شود، توزیع متغیر تصادفی فوق به نرمال استاندارد میل می‌کند، یعنی:

$$t(n) \xrightarrow{n \rightarrow +\infty} N(0,1)$$


توزیع F (توزیع فیشر):

این توزیع در مسائل مختلف تست فرضیه در آمار ظاهر می‌شود.

گوئیم x دارای توزیع F با درجه‌های آزادی k و m است: $x \sim F(k, m)$ ، هرگاه:

$$f_x(x) = \gamma \frac{x^{\frac{k}{2}-1}}{\left(1 + \frac{kx}{m}\right)^{\frac{k+m}{2}}} : x > 0 \quad \rightarrow \quad \gamma = \frac{\Gamma\left(\frac{k+m}{2}\right)}{\Gamma\left(\frac{k}{2}\right)\Gamma\left(\frac{m}{2}\right)} \left(\frac{k}{m}\right)^{\frac{k}{2}}$$

(ترتیب k و m مهم است.)



قضیه خاصیت اساسی توزیع F: اگر $z \sim \chi^2(k)$ و $w \sim \chi^2(r)$ بوده و مستقل باشند و داشته باشیم:

$$x = \frac{\frac{z}{k}}{\frac{w}{r}}$$

آنگاه:

$$x \sim F(k, r)$$

مشابه توزیع t ، مثلاً با روش متغیر تصادفی کمکی می‌توان f_x را به دست آورد و نشان داد که فرم فوق‌الذکر را دارد. اثبات در کتاب، صفحات ۲۲۴ و ۲۲۵.

ضمناً اگر $z \sim \chi^2(k, e)$ و $w \sim \chi^2(r)$ باشند، در این صورت: $x \sim F(k, r, e)$ ، یعنی دارای توزیع F غیرمرکزی با درجه‌های آزادی k و r و خروج از مرکز e خواهد بود.

به توجه به قضیه فوق برای توزیع F داریم:

$$E(x) = \frac{r}{k} E(z) E\left(\frac{1}{w}\right) = \frac{r}{k} \cdot k \cdot \frac{1}{r-2} = \frac{r}{r-2} : r > 2$$

نتيجة ١:

$$\mathbf{x} \sim F(k,r) \Rightarrow \frac{1}{\mathbf{x}} \sim F(r,k)$$

نتيجة ٢:

$$\mathbf{x} \sim t(m) \Rightarrow \mathbf{x}^2 \sim F(1,m)$$

زیرا:

$$\begin{cases} \mathbf{x} \sim \frac{\mathbf{z}}{\sqrt{\frac{\mathbf{w}}{m}}} \\ \mathbf{z} \sim N(0,1) \\ \mathbf{w} \sim \chi^2(m) \end{cases} \Rightarrow \begin{cases} \mathbf{x}^2 \sim \frac{\mathbf{z}^2}{\frac{\mathbf{w}}{m}} \\ \mathbf{z}^2 \sim \chi^2(1) \\ \mathbf{w} \sim \chi^2(m) \end{cases} \Rightarrow \mathbf{x}^2 \sim F(1,m)$$

نتيجة ٣:

$$\mathbf{x} \sim F(\mathbf{k}, \mathbf{r}) \Rightarrow \underset{\mathbf{r} \rightarrow +\infty}{\mathbf{kx}} \sim \chi^2(\mathbf{k})$$

زیرا:

$$\left\{ \begin{array}{l} \mathbf{kx} = \frac{\mathbf{z}}{\frac{\mathbf{w}}{\mathbf{r}}} \\ \mathbf{z} \sim \chi^2(\mathbf{k}) \\ \mathbf{w} \sim \chi^2(\mathbf{r}) \Rightarrow \frac{\mathbf{w}}{\mathbf{r}} \xrightarrow{\mathbf{r} \rightarrow +\infty} 1 \end{array} \right. \Rightarrow \underset{\mathbf{r} \rightarrow +\infty}{\mathbf{kx}} \rightarrow \mathbf{z}$$