

Distribuții de probabilitate clasice

Principalele legi de probabilitate

Radu Trîmbițaș

December 2012

Conținut

Cuprins

1 Distribuții discrete	1
1.1 Repartiția binomială	1
1.2 Repartiția Poisson	2
2 Distribuții continue	3
2.1 Repartiția uniformă	3
2.2 Repartiția normală	4
2.3 Familia de repartiții gama	9
2.4 Repartiția hi-pătrat	11
2.5 Repartiția Student	13
2.6 Repartiția F	17

1 Distribuții discrete

1.1 Repartiția binomială

Repartiția binomială

- Variabila aleatoare X având distribuția

$$X : \left(\binom{n}{k} p^k q^{n-k} \right)_{k=1, \dots, n}, \quad q = 1 - p$$

se numește variabilă aleatoare **binomială**. Repartiția astfel determinată se numește **repartiție binomială** de ordinul n și parametru p .

- Mulțimea tuturor variabilelor aleatoare binomiale de ordinul n și parametru p se va nota cu $b(p, n)$.

Observația 1. Dacă

$$X_k : \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix}$$

atunci $Y = X_1 + X_2 + \dots + X_n \in b(p, n)$ (Y este o variabilă aleatoare care ia valoarea k dacă evenimentul $A := (X_k = 1)$ s-a produs de k ori).

Teorema 2. Valoarea medie și dispersia unei variabile aleatoare binomiale de ordin n și parametru p sunt

$$M(X) = np, \quad D^2(X) = npq.$$

Demonstrație. Demonstrația se bazează pe observația 1. Dacă

$$X_k : \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix},$$

atunci $M(X_k) = p$, $D^2(X_k) = pq$ și deoarece X_k sunt independente, avem

$$\begin{aligned} M(X) &= M(Y) = M\left(\sum_{k=1}^n X_k\right) = np, \\ D^2(X) &= D^2(Y) = D^2\left(\sum_{k=1}^n X_k\right) = npq. \end{aligned}$$

■

Funcția caracteristică a repartiției binomiale este

$$\begin{aligned} g(t) &= M(e^{itX}) = \sum_{k=0}^n e^{itk} \binom{n}{k} p^k q^{n-k} \\ &= \sum_{k=0}^n \binom{n}{k} (pe^{it})^k q^{n-k} = (pe^{it} + q)^n. \end{aligned}$$

1.2 Repartiția Poisson

Repartiția Poisson

- Repartiția discretă determinată de probabilitățile

$$P(k; \lambda) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad (1)$$

unde $k \in \mathbb{N}$ și $\lambda > 0$ se numește **repartiție Poisson** de parametru λ . Variabila aleatoare cu distribuția

$$X : \left(\frac{\lambda^k}{k!} e^{-\lambda} \right)_{k \in \mathbb{N}} \quad (2)$$

se numește **variabilă aleatoare Poisson**.

- Vom nota cu $Po(\lambda)$ mulțimea variabilelor aleatoare Poisson de parametru λ .
- Relația (1) se poate obține pornind de la o repartiție binomială. Punem $np = \lambda$ și trecând la limită pentru $n \rightarrow \infty$ (menținând λ constant) avem

$$\begin{aligned}\lim_{n \rightarrow \infty} P(n; \lambda) &= \lim_{n \rightarrow \infty} \frac{n(n-1) \dots (n-k+1)}{k!} \cdot \frac{\lambda^k}{n^k} \left(1 - \frac{\lambda}{n}\right)^{n-k} = \\ &= \frac{\lambda^k}{k!} e^{-\lambda}\end{aligned}$$

căci

$$\lim_{n \rightarrow \infty} \frac{n(n-1) \dots (n-k+1)}{n^k} = 1 \text{ și } \lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^{n-k} = e^{-\lambda}.$$

- Din acest motiv repartiția Poisson se mai numește și *legea evenimentelor rare*.

Teorema 3. Valoarea medie și dispersia unei variabile aleatoare Poisson de parametru λ sunt $M(X) = \lambda$ și $D^2(X) = \lambda$.

Demonstrație. Deoarece

$$M(X) = \sum_{k=0}^{\infty} k \frac{\lambda^k}{k!} e^{-\lambda} = \lambda e^{-\lambda} \sum_{k=1}^{\infty} \frac{\lambda^{k-1}}{(k-1)!} = \lambda e^{-\lambda} e^{\lambda} = \lambda$$

și

$$\begin{aligned}M(X^2) &= \sum_{k=0}^{\infty} k^2 \frac{\lambda^k}{k!} e^{-\lambda} = \sum_{k=0}^{\infty} (k^2 - k + k) \frac{\lambda^k}{k!} e^{-\lambda} = \\ &= \sum_{k=1}^{\infty} k(k-1) \frac{\lambda^k}{k!} e^{-\lambda} + \sum_{k=0}^{\infty} k \frac{\lambda^k}{k!} e^{-\lambda} = \lambda^2 e^{-\lambda} e^{\lambda} + \lambda = \lambda^2 + \lambda,\end{aligned}$$

obținem $D^2(X) = M(X^2) - [M(X)]^2 = \lambda$. ■

- Funcția caracteristică a unei variabile aleatoare Poisson are expresia

$$g(t) = \sum_{k=0}^{\infty} e^{ikt} \frac{\lambda^k}{k!} e^{-\lambda} = e^{\lambda(e^{it}-1)}.$$

- Cu ajutorul funcției caracteristice se verifică ușor că suma a două variabile aleatoare Poisson de parametru λ și respectiv μ este o variabilă aleatoare Poisson de parametru $\lambda + \mu$.

2 Distribuții continue

2.1 Repartiția uniformă

Repartiția uniformă

- O variabilă aleatoare X având densitatea de probabilitate

$$f(x) = \begin{cases} \frac{1}{b-a} & \text{pentru } x \in [a, b] \\ 0 & \text{pentru } x \notin [a, b] \end{cases} \quad (3)$$

se numește **variabilă aleatoare uniformă** pe $[a, b]$, iar densitatea de probabilitate și funcția de repartiție corespunzătoare se numesc densitate de probabilitate și respectiv funcție de repartiție uniformă pe $[a, b]$.

- Mulțimea variabilelor aleatoare uniforme pe $[a, b]$ se notează cu $U[a, b]$.
- Se verifică imediat că funcția de repartiție uniformă pe $[a, b]$ este

$$F(x) = \begin{cases} 0, & \text{pentru } x \leq a \\ \frac{x-a}{b-a}, & \text{pentru } a < x \leq b \\ 1, & \text{pentru } x > b. \end{cases}$$

Graficele lui f și F apar în figura 1.

Teorema 4. *Valoarea medie și dispersia unei variabile aleatoare uniforme sunt*

$$M(X) = \frac{a+b}{2}, \quad D^2(X) = \frac{(b-a)^2}{12}.$$

Demonstrație.

$$\begin{aligned} M(X) &= \int_{-\infty}^{\infty} xf(x)dx = \int_{-\infty}^a xf(x)dx + \int_a^b xf(x)dx + \int_b^{\infty} xf(x)dx = \\ &= \int_a^b xf(x)dx = \frac{1}{b-a} \frac{x^2}{2} \Big|_a^b = \frac{b^2 - a^2}{2(b-a)} = \frac{a+b}{2}. \end{aligned}$$

De asemenea

$$M(X^2) = \int_{-\infty}^{\infty} x^2 f(x)dx = \frac{1}{b-a} \int_a^b x^2 dx = \frac{a^2 + ab + b^2}{3},$$

de unde

$$D^2(X) = \frac{a^2 + ab + b^2}{3} - \frac{a^2 + 2ab + b^2}{4} = \frac{(b-a)^2}{12}.$$

■

- Ținând cont că $b > a$ avem $D(X) = \frac{b-a}{2\sqrt{3}}$.
- Funcția caracteristică pentru $X \in U[a, b]$ este

$$g(t) = \frac{e^{itb} - e^{ita}}{it(b-a)}.$$




Figura 1: Densitatea de probabilitate și funcția de repartiție pentru $U[0,2]$

2.2 Repartiția normală

Repartiția normală

- Spunem că variabila aleatoare X urmează **legea normală** de parametri m și σ^2 (sau uneori m și σ), $m \in \mathbb{R}$, $\sigma > 0$ dacă densitatea sa de probabilitate este

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}. \quad (4)$$

- Mulțimea variabilelor aleatoare ce urmează legea normală de parametri m și σ^2 se va nota cu $N(m, \sigma^2)$.
- Funcția de repartiție este

$$F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(t-m)^2}{2\sigma^2}} dt.$$

- Dacă $m = 0$ și $\sigma^2 = 1$ se obține

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad (5)$$

și spunem că X urmează **repartiția normală standard** sau **redușă**, notată cu $N(0, 1)$.

Teorema 5. Media și dispersia unei variabile aleatoare normale reduse sunt $M(X) = 0$ și $D^2(X) = 1$.

Demonstrație.

$$M(X) = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} x e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x e^{-\frac{x^2}{2}} dx = 0,$$

deoarece funcția de integrat este impară.

$$D^2(X) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} (x - m)^2 e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^2 e^{-\frac{x^2}{2}} dx.$$

Integrala se calculează prin părți, luând $u = x$ și $dv = x e^{-\frac{x^2}{2}}$, obținându-se

$$D^2(X) = \frac{1}{\sqrt{2\pi}} \left[-x e^{-\frac{x^2}{2}} \Big|_{-\infty}^{\infty} + \int_{-\infty}^{\infty} e^{-\frac{x^2}{2}} dx \right] = 1,$$

deoarece

$$\int_0^{\infty} e^{-x^2} dx = \sqrt{\pi}. \quad (\text{integrala lui Poisson})$$

■

Corolarul 6. Media și dispersia unei variabile aleatoare normale, de parametri m și σ^2 sunt $M(X) = m$ și $D^2(X) = \sigma^2$.

Demonstrație. Temă. ■

Observația 7. Parametri m și σ^2 ai repartiției normale reprezintă valoarea medie și respectiv dispersia unei variabile aleatoare repartizată $N(m, \sigma^2)$. Rezultă totodată că funcția de repartiție a unei variabile aleatoare normale este perfect determinată de valoarea medie și dispersia variabilei.

Momentele de ordin impar ale repartiției normale standard sunt nule, deoarece funcția de integrat care intervine la calculul lor este impară.

$$M_{2k+1}(X) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^{2k+1} e^{-\frac{x^2}{2}} dx = 0.$$

Pentru momentele de ordin par avem

$$\begin{aligned} M_{2k}(X) &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^{2k} e^{-\frac{x^2}{2}} dx = -\frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^{2k-1} \left(e^{-\frac{x^2}{2}} \right)' dx = \\ &= (2k-1) M_{2k-2}(x). \end{aligned}$$

Deci am obținut

$$M_{2k+1}(X) = 0 \quad (6)$$

$$M_{2k}(X) = (2k-1)!! = \frac{(2k)!}{2^k k!}.$$

Asimetria și excesul pentru o variabilă aleatoare normală X sunt

$$As = \frac{M_3(X)}{\sigma^3} = 0, \quad E = \frac{M_4(X)}{\sigma^4} - 3 = 0.$$

În faptul că asimetria și excesul repartiției $N(m, \sigma^2)$ sunt nule își are originea procedeul statisticii descriptive de a considera aceste caracteristici drept criterii de stabilire a normalității. Totuși, condiția $As = E = 0$ este o condiție necesară, dar nu suficientă pentru normalitate.

Funcția de repartiție a unei variabile aleatoare normale standard este

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \quad (7)$$

și se numește *funcția lui Laplace*. Deoarece densitatea de probabilitate normală standard este simetrică față de dreapta $x = 0$ rezultă $\Phi(-x) = 1 - \Phi(x)$.

Cu ajutorul funcției Φ , prin schimbarea de variabilă $u = \frac{x-m}{\sigma}$ se determină probabilităților ce privesc orice variabilă aleatoare normală:

$$\begin{aligned} P(a < X < b) &= \int_a^b f(x) dx = \int_{-\infty}^b f(x) dx - \int_{-\infty}^a f(x) dx = \\ &= \frac{1}{\sqrt{2\pi}} \left[\int_{-\infty}^{\frac{b-m}{\sigma}} e^{-\frac{u^2}{2}} du - \int_{-\infty}^{\frac{a-m}{\sigma}} e^{-\frac{u^2}{2}} du \right] = \\ &= \Phi\left(\frac{b-m}{\sigma}\right) - \Phi\left(\frac{a-m}{\sigma}\right). \end{aligned}$$

Reprezentarea grafică

Interpretarea geometrică a funcției lui Laplace

Regula celor 3 sigma

Regula celor 3 σ pentru variabile aleatoare normale.

$$\begin{aligned} P(|x - m| < \varepsilon) &= P(-\varepsilon + m < X < \varepsilon + m) = \Phi\left(\frac{\varepsilon}{\sigma}\right) - \Phi\left(-\frac{\varepsilon}{\sigma}\right) = \\ &= 2\Phi\left(\frac{\varepsilon}{\sigma}\right) - 1. \end{aligned}$$

Luând $\varepsilon = 3\sigma$, obținem

$$p = P(|x - m| < \varepsilon) = 2\Phi(3) - 1.$$

În tabele găsim $\Phi(3) = 0.9987$, de unde $p = 0.9974$. Cu alte cuvinte, probabilitatea ca abaterea în valoare absolută să depășească 3σ este $1 - 0.9974 = 0.0026$, adică practic 0.





Figura 2: Densitatea de probabilitate (sus) și funcția de repartiție $N(0, 1)$



Funcția caracteristică

Vom calcula întâi funcția caracteristică a unei variabile aleatoare normale standard. Avem

$$g(t) = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{itx} e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \sum_{n=0}^{\infty} \frac{t^n i^n}{n!} x^n e^{-\frac{x^2}{2}} dx.$$

Deoarece seria din membrul drept este uniform convergentă putem permuta suma cu integrala, obținând

$$g(t) = \sum_{n=0}^{\infty} \frac{t^n i^n}{n!} \cdot \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} x^n e^{-\frac{x^2}{2}} dx = \sum_{n=0}^{\infty} \frac{t^n i^n}{n!} M_n(X).$$

Ținând cont de expresiile (6) ale momentelor repartiției normale standard avem în final

$$g(t) = \sum_{m=0}^{\infty} \frac{t^{2m} i^{2m}}{(2m)!} \cdot \frac{(2m)!}{2^m m!} = \sum_{m=0}^{\infty} \frac{(-t^2/2)^m}{m!} = e^{-\frac{t^2}{2}}.$$

Pentru o variabilă aleatoare $X \in N(m, \sigma^2)$, deoarece $Y = \frac{x-m}{\sigma}$ este normală standard obținem

$$g_X(t) = g_{\sigma Y + m}(t) = e^{itm} g_Y(\sigma t) = e^{itm - \frac{\sigma^2 t^2}{2}}.$$

Cu ajutorul funcției caracteristice se poate demonstra:

Teorema 8. Dacă $a_1, \dots, a_n$ sunt constante și $X_1, \dots, X_n$ sunt variabile aleatoare independente, repartizate $N(m_k, \sigma_k^2)$, $k = \overline{1, n}$, atunci variabila aleatoare $Y = a_1 X_1 + \dots + a_n X_n$ este repartizată $N(\sum_{k=1}^n a_k m_k, \sum_{k=1}^n a_k^2 \sigma_k^2)$.

2.3 Familia de repartiții gama

Familia de repartiții gama

- Spunem că variabila aleatoare X urmează **legea gama** de parametri $r > 0$ și $\lambda > 0$ dacă densitatea sa de probabilitate este

$$f(x; r, \lambda) = \begin{cases} \frac{\lambda e^{-\lambda x} (\lambda x)^{r-1}}{\Gamma(r)}, & \text{pentru } x > 0 \\ 0, & \text{pentru } x \leq 0, \end{cases} \quad (8)$$

unde $\Gamma(r)$ reprezintă valoarea funcției gama a lui Euler în r .

- Mulțimea variabilelor aleatoare ce urmează legea gama de parametri r și λ se va nota cu $\gamma(r, \lambda)$.
- Pentru $\lambda = 1$ se obține repartiția **gama standard** de parametru r , având densitatea de probabilitate

$$f(x; r) = \begin{cases} \frac{e^{-x} x^{r-1}}{\Gamma(r)}, & \text{pentru } x > 0 \\ 0, & \text{pentru } x \leq 0. \end{cases}$$

- Mulțimea variabilelor aleatoare ce urmează legea gama standard de parametru r se va nota cu $\gamma^*(r)$.

Observația 9. Are loc $X \in \gamma(r, \lambda) \Rightarrow aX \in \gamma(r, \frac{\lambda}{a})$.

Să determinăm funcția caracteristică a unei variabile aleatoare $X \in \gamma^*(r)$.

$$\begin{aligned} g(t) &= \frac{1}{\Gamma(r)} \int_0^\infty e^{itx} e^{-x} x^{r-1} dx = \frac{1}{\Gamma(r)} \int_0^\infty \left(\sum_{n=0}^\infty \frac{(itx)^n}{n!} \right) e^{-x} x^{r-1} dx \\ &= \frac{1}{\Gamma(r)} \sum_{n=0}^\infty \frac{(it)^n}{n!} \int_0^\infty e^{-x} x^{n+r-1} dx = \frac{1}{\Gamma(r)} \sum_{n=0}^\infty \frac{\Gamma(n+r)}{n!} (it)^n \\ &= 1 + \sum_{n=0}^\infty \frac{r(r+1) \dots (r+n-1)}{n!} (it)^n = (1 - it)^{-r}. \end{aligned}$$

Deci $g(t) = (1 - it)^{-r}$.

Dacă $X \in \gamma(r, \lambda)$, atunci aX are densitatea de probabilitate $f(\frac{x}{a})$; deci conform observației 9 $aX \in \gamma(r, \frac{\lambda}{a})$ și

$$g_X(t) = \left(1 - \frac{it}{\lambda}\right)^{-r} = \frac{\lambda^r}{(\lambda - it)^r},$$

căci dacă $X \in \gamma(r, \lambda)$, $\lambda X \in \gamma^*(r)$.

Momentele de ordinul s ale lui $X \in \gamma(r, \lambda)$ sunt

$$M_s(X) = \frac{1}{\Gamma(r)} \int_0^\infty x^s \lambda e^{-\lambda x} (\lambda x)^{r-1} dx = \frac{1}{\lambda^s \Gamma(r)} \int_0^\infty e^{-y} y^{r+s-1} dy$$

și deci

$$M_s(X) = \frac{\Gamma(r+s)}{\lambda^s \Gamma(r)},$$

de unde

$$M(X) = \frac{r}{\lambda}, \quad M_2(X) = \frac{r(r+1)}{\lambda^2}, \quad D^2(X) = \frac{r}{\lambda^2}.$$

Observația 10. Pentru $r = 1$, $\gamma(1, \lambda)$ devine **legea exponențială** de parametru λ . Densitatea sa de probabilitate este

$$f(x; \lambda) = \begin{cases} \lambda e^{-\lambda x}, & \text{pentru } x > 0 \\ 0, & \text{pentru } x \leq 0. \end{cases}$$

Prin calcul se obține

$$F(x; \lambda) = \begin{cases} 1 - e^{-\lambda x}, & \text{pentru } x > 0 \\ 0, & \text{pentru } x \leq 0, \end{cases}$$

iar prin particularizarea rezultatelor de mai sus

$$M(X) = M_1(X) = \frac{1}{\lambda}, \quad M_2(X) = \frac{2}{\lambda^2}, \quad D^2(X) = \frac{1}{\lambda^2}, \quad g(x) = \frac{\lambda}{\lambda - it}.$$

Teorema 11. Dacă $X \in N(m, \sigma^2)$ atunci $Y = \frac{(X-m)^2}{2\sigma^2} \in \gamma^*(\frac{1}{2})$.

Demonstrație. Avem

$$P(Y < x) = P\left(-\sqrt{x} < \frac{X-m}{\sigma\sqrt{2}} < \sqrt{x}\right) = P\left(-\sqrt{2x} < \frac{X-m}{\sigma} < \sqrt{2x}\right).$$

Deoarece $\frac{X-m}{\sigma} \in N(0, 1)$, obținem

$$P(Y < x) = \frac{1}{\sqrt{2\pi}} \int_{-\sqrt{2x}}^{\sqrt{2x}} e^{-\frac{u^2}{2}} du = \frac{2}{\sqrt{2\pi}} \int_0^{\sqrt{2x}} e^{-\frac{u^2}{2}} du.$$

Efectuând schimbarea de variabilă $u^2 = 2v$ și ținând cont că $\Gamma(1/2) = \sqrt{\pi}$, rezultă că

$$P(Y < x) = \frac{1}{\Gamma(\frac{1}{2})} \int_0^x e^{-v} v^{-\frac{1}{2}} dv = F_Y(x),$$

adică

$$f_Y(x) = \begin{cases} \frac{e^{-x} x^{\frac{1}{2}-1}}{\Gamma(\frac{1}{2})}, & \text{pentru } x > 0 \\ 0, & \text{pentru } x \leq 0 \end{cases} = f_{\gamma^*}(x; \frac{1}{2}).$$

■

2.4 Repartiția hi-pătrat

Repartiția hi-pătrat

Spunem că variabila aleatoare X urmează **legea** χ^2 (se citește **hi-pătrat**) de parametri $\nu > 0$ (număr de grade de libertate) și $\sigma^2 > 0$ dacă $X \in \gamma(\frac{\nu}{2}, \frac{1}{2\sigma^2})$. Pentru densitatea de probabilitate din (8) se obține

$$f(x; m, \sigma^2) = \begin{cases} \frac{e^{-\frac{x}{2\sigma^2}} x^{\frac{\nu}{2}-1}}{(2\sigma^2)^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})}, & \text{pentru } x > 0 \\ 0, & \text{pentru } x \leq 0. \end{cases}$$

Această repartiție a fost descoperită de astronomul Helmert în 1876 și pusă în valoare 30 de ani mai târziu de Karl Pearson, motiv pentru care se mai numește și **repartiția Helmert-Pearson**. Pentru $\sigma^2 = 1$ se obține repartiția χ^2 standard cu $\nu > 0$ grade de libertate, având densitatea de probabilitate

$$f(x; \nu) = \begin{cases} \frac{e^{-\frac{x}{2}} x^{\frac{\nu}{2}-1}}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})}, & \text{pentru } x > 0 \\ 0, & \text{pentru } x \leq 0. \end{cases}$$

Mulțimea variabilelor aleatoare ce urmează legea χ^2 de parametri ν și σ^2 se va nota cu $\chi^2(\nu, \sigma^2)$ sau cu $X^2(\nu, \sigma^2)$. În figura 3 apar mai multe exemple de distribuții χ^2 standard, cu diverse grade de libertate. Funcția caracteristică este

$$g(x) = (1 - 2\sigma^2 ti)^{-\frac{\nu}{2}}$$

și se obține din funcția caracteristică a repartiției gama (ec. 8) pentru $r = \frac{\nu}{2}$ și $\lambda = \frac{1}{2\sigma^2}$.

Momentele de ordinul s sunt

$$M_s(X) = \frac{(2\sigma^2)^s \Gamma(s + \frac{\nu}{2})}{\Gamma(\frac{\nu}{2})}$$

și deci $M(X) = \nu\sigma^2$, $M_2(X) = \nu(\nu + 2)\sigma^4$, $D^2(X) = 2\nu\sigma^4$.

Teorema 12. Dacă $X_1, \dots, X_\nu \in N(0, \sigma^2)$ și ele sunt independente, atunci

$$Y = X_1^2 + \dots + X_\nu^2 \in X^2(\nu, \sigma^2).$$

Demonstrație. Conform teoremei 11 $X_j \in N(0, \sigma^2) \Rightarrow Y_j = \frac{X_j^2}{2\sigma^2} \in \gamma^*(\frac{1}{2}) \Leftrightarrow X_j^2 \in \gamma(\frac{1}{2}, \frac{1}{2\sigma^2}) \Leftrightarrow X_j^2 \in X^2(1, \sigma^2)$. Deoarece $X_1, \dots, X_\nu$ sunt independente

$$g_Y(t) = g_{X_1^2}(t) \cdots g_{X_\nu^2}(t) = (1 - 2\sigma^2 ti)^{-\frac{\nu}{2}}$$

adică $Y \in X^2(\nu, \sigma^2)$. ■

Teorema 13. Fie $X \in X^2(\nu, \sigma^2)$. Pentru $\nu \rightarrow \infty$, $X^* = \frac{X - M(X)}{D(X)}$ urmează legea normală standard $N(0, 1)$.

Demonstrație. Avem $M(X) = \nu\sigma^2$, $D^2(X) = 2\nu\sigma^4$ și deci

$$X^* = \frac{X - \nu\sigma^2}{\sqrt{2\nu\sigma^4}} = \frac{X}{\sigma^2\sqrt{2\nu}} - \sqrt{\frac{\nu}{2}},$$

din care se obține

$$\begin{aligned} g_{X^*}(t) &= e^{-it\sqrt{\frac{\nu}{2}}} g_X\left(\frac{t}{\sigma^2\sqrt{2\nu}}\right) = e^{-it\sqrt{\frac{\nu}{2}}} \left(1 - it\sqrt{\frac{2}{\nu}}\right)^{-\frac{\nu}{2}} = \\ &= \left(e^{it\sqrt{\frac{2}{\nu}}} \left(1 - it\sqrt{\frac{2}{\nu}}\right)\right)^{-\frac{\nu}{2}}. \end{aligned}$$

Dezvoltăm în serie primul factor

$$e^{it\sqrt{\frac{2}{\nu}}} = e^{\frac{it}{\sqrt{\nu/2}}} = 1 + it\sqrt{\frac{2}{\nu}} - \frac{t^2}{\nu} + \Theta(\nu^{-3/2}),$$

înlocuim în al doilea și obținem

$$g_{X^*}(t) = 1 + \frac{t^2}{\nu} + \Theta(\nu^{-3/2}),$$

de unde

$$g_{X^*}(t) = \exp\left(\lim_{\nu \rightarrow \infty} \left(-\frac{t^2}{2} - \Theta(\nu^{-1/2})\right)\right),$$

adică funcția caracteristică pentru $N(0, 1)$. ■




Figura 3: Densități de probabilitate χ^2

Reprezentarea grafică

2.5 Repartiția Student

Repartiția Student

- Spunem că variabila aleatoare X urmează *legea Student* sau *legea T* cu $\nu > 0$ grade de libertate dacă densitatea sa de probabilitate este

$$f(x|\nu) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi\nu}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}. \quad (9)$$

- Mulțimea variabilelor aleatoare ce urmează legea Student cu ν grade de libertate se notează cu $T(\nu)$ sau $S^*(\nu)$.
- Deoarece f este o funcție pară momentele de ordin impar $M_{2k+1}(X)$ sunt nule, $M(X) = 0$, iar momentele centrate coincid cu momentele obișnuite. Pentru calculul momentelor de ordin par efectuăm substituția $x^2 = \nu y$ și

obținem

$$M_{2k}(X) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi\nu}\Gamma\left(\frac{\nu}{2}\right)} \int_{-\infty}^{\infty} x^{2k} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}} dx = \quad (10)$$

$$\begin{aligned} &= \frac{\nu^k \Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi}\Gamma\left(\frac{\nu}{2}\right)} \int_0^{\infty} y^{k-\frac{1}{2}} (1+y)^{-\frac{\nu+1}{2}} dy = \\ &= \frac{\nu^k \Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi}\Gamma\left(\frac{\nu}{2}\right)} B\left(\frac{\nu}{2} - k, k + \frac{1}{2}\right) = \\ &= \frac{\nu^k \Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi}\Gamma\left(\frac{\nu}{2}\right)} \frac{\Gamma\left(\frac{\nu}{2} - k\right) \Gamma\left(k + \frac{1}{2}\right)}{\Gamma\left(\frac{\nu+1}{2}\right)}, \quad 0 < k < \frac{\nu}{2} \end{aligned} \quad (11)$$

Dar

$$\Gamma\left(\frac{\nu}{2}\right) = \left(\frac{\nu}{2} - 1\right) \cdots \left(\frac{\nu}{2} - k\right) \Gamma\left(\frac{\nu}{2} - k\right)$$

și

$$\Gamma\left(k + \frac{1}{2}\right) = \left(k - \frac{1}{2}\right) \cdots \frac{1}{2} \Gamma\left(\frac{1}{2}\right),$$

de unde

$$M_{2k}(X) = \frac{1 \cdot 3 \cdots (2k-1)}{(\nu-2)(\nu-4) \cdots (\nu-2k)} \nu^k \quad (12a)$$

cu condiția să avem $k < \frac{\nu}{2}$.

- Deci, primele două momente de ordin par, dacă există sunt

$$M_2(X) = m_2(X) = \frac{\nu}{\nu-2}, \quad M_4(X) = m_4(X) = \frac{3\nu^2}{(\nu-2)(\nu-4)}.$$

- Din relația (12a) obținem

$$\lim_{n \rightarrow \infty} M_{2k}(X) = (2k-1)!!$$

și deoarece $M_{2k+1}(X) = 0$, rezultă că momentele repartiției Student tind la momentele repartiției $N(0,1)$ când $n \rightarrow \infty$. Am demonstrat astfel teorema:

Teorema 14. Dacă $X \in T(\nu)$, atunci X este asimptotic normală standard (când $\nu \rightarrow \infty$).

În figura 4 apar mai multe grafice de densități de probabilitate Student pentru diverse grade de libertate.

Reprezentarea grafică




Figura 4: Densități de probabilitate Student pentru $\nu = 1, 5, 10, 30$ grade de libertate

Repartiția Student

Teorema 15. Dacă $X \in N(0, \sigma^2)$ și $Y \in X^2(\nu, \sigma^2)$ sunt variabile aleatoare independente, atunci variabila aleatoare

$$Z = \frac{X}{\sqrt{\frac{Y}{\nu}}}$$

urmează legea $T(\nu)$.

Demonstrație. Densitatea de probabilitate $f(x, y)$ a vectorului aleator (X, Y) este $f(x, y) = f_X(x)f_Y(y)$. Deoarece $x = z\sqrt{\frac{y}{\nu}}$ și $y = y$ avem

$$\frac{D(x, y)}{D(z, y)} = \begin{vmatrix} \sqrt{\frac{y}{\nu}} & \frac{z}{2\sqrt{\nu y}} \\ 0 & 1 \end{vmatrix} = \sqrt{\frac{y}{\nu}},$$

de unde rezultă că

$$f(z, y) = f_X\left(z\sqrt{\frac{y}{\nu}}\right) f_Y(y) \sqrt{\frac{y}{\nu}}.$$

Densitatea de probabilitate a lui Z este

$$f(z) = \int_0^\infty f(z, y) dy = \frac{1}{\sqrt{2\pi\nu}\Gamma\left(\frac{\nu}{2}\right) (2\sigma^2)^{\frac{\nu}{2}}} \int_0^\infty e^{-\frac{y}{2\sigma^2}\left(1+\frac{z^2}{\nu}\right)} y^{\frac{\nu-1}{2}} dy;$$

efectuând schimbarea de variabilă $y = \frac{2\sigma^2}{1+z^2/\nu}t$, vom avea în final

$$f(z) = \frac{\left(1 + \frac{z^2}{\nu}\right)^{\frac{\nu+1}{2}}}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \int_0^\infty e^{-t} t^{\frac{\nu+1}{2}-1} dt = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi\nu}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{z^2}{\nu}\right)^{-\frac{\nu+1}{2}}.$$

■

Din teoremele 15 și 12 rezultă

Teorema 16. Dacă $X_0, X_1, \dots, X_v$ sunt variabile aleatoare independente de clasă $N(0, \sigma^2)$, atunci variabila aleatoare

$$Y = \frac{X_0}{\sqrt{\frac{X_1^2 + \dots + X_v^2}{v}}}$$

este de clasă $T(v)$.

Un alt rezultat util de acest tip este

Teorema 17. Dacă $X_1, \dots, X_v$ sunt variabile aleatoare independente de clasă $N(0, \sigma^2)$ și

$$Y = \frac{X_1 + \dots + X_v}{v}, \quad (13)$$

atunci variabila aleatoare

$$Z = \frac{Y}{\sqrt{\frac{\sum_{i=1}^v (X_i - Y)^2}{v(v-1)}}} \quad (14)$$

apartine clasei $T(v-1)$.

Demonstrație. Fie variabilele aleatoare

$$Y_i = \sum_{j=1}^v a_{ij} X_j, \quad i = \overline{1, v-1} \quad (15)$$

și

$$Y_v = \frac{1}{\sqrt{v}} (X_1 + \dots + X_v) \quad (16)$$

cu coeficienții aleși astfel încât matricea $A = (a_{ij})$ să fie ortogonală. Deoarece $X_1, \dots, X_v$ sunt variabile aleatoare independente de clasă $N(0, \sigma^2)$, rezultă că și $Y_1, \dots, Y_v$ sunt independente și de clasă $N(0, \sigma^2)$. Mai mult

$$Y_1^2 + \dots + Y_v^2 = X_1^2 + \dots + X_v^2 \quad (17a)$$

de unde

$$\begin{aligned} Y_1^2 + \dots + Y_{v-1}^2 &= X_1^2 + \dots + X_v^2 - \frac{X_1^2 + \dots + X_v^2}{v} = \\ &= X_1^2 + \dots + X_v^2 - vY^2 = \sum_{i=1}^v (X_i - Y)^2 \end{aligned} \quad (18)$$

Utilizând (13), (14), (16) și (18) obținem

$$\begin{aligned} Z &= \frac{\frac{1}{\sqrt{v}} \sqrt{v(v-1)}(X_1 + \dots + X_v)}{\sqrt{\sum_{i=1}^v (X_i - Y)^2}} = \frac{\frac{1}{\sqrt{v}} \sqrt{v(v-1)} \sqrt{v} Y_v}{\sqrt{\sum_{i=1}^v Y_i^2}} = \\ &= \frac{Y_v}{\sqrt{\frac{Y_1^2 + \dots + Y_{v-1}^2}{v-1}}} \end{aligned}$$

și conform teoremei precedente $Z \in T(v-1)$. ■

În figura 5 apar pe același grafic o distribuție $N(0, 1)$ și o distribuție $T(5)$.




Figura 5: Comparație între $N(0, 1)$ și $T(5)$

2.6 Repartiția F

Repartiția F

Spunem că o variabilă aleatoare are **repartiția F** sau **repartiția Snedecor-Fisher** cu $\nu_1 > 0$ și $\nu_2 > 0$ grade de libertate dacă densitatea sa de probabilitate este

$$f(x; \nu_1, \nu_2) = \begin{cases} \left(\frac{\nu_1}{\nu_2}\right)^{\frac{\nu_1}{2}} \frac{x^{\frac{\nu_1}{2}-1}}{B\left(\frac{\nu_1}{2}, \frac{\nu_2}{2}\right) \left(1 + \frac{\nu_1}{\nu_2}x\right)^{\frac{\nu_1+\nu_2}{2}}} & \text{pentru } x > 0 \\ 0 & \text{pentru } x \leq 0. \end{cases} \quad (19)$$

Mulțimea variabilelor cu această repartiție se va nota cu $F(\nu_1, \nu_2)$. Momentele de ordinul r ale unei variabile aleatoare $X \in F(\nu_1, \nu_2)$ sunt

$$M_r(X) = \left(\frac{\nu_1}{\nu_2}\right)^r \frac{\Gamma\left(\frac{\nu_1}{2} + r\right) \Gamma\left(\frac{\nu_2}{2} - r\right)}{\Gamma\left(\frac{\nu_1}{2}\right) \Gamma\left(\frac{\nu_2}{2}\right)}, \quad (20)$$

cu condiția ca $0 < 2r < \nu_2$. Pentru r întreg se obține:

$$M_r(X) = \left(\frac{\nu_1}{\nu_2}\right)^r \frac{\nu_1(\nu_1 + 2) \dots (\nu_1 + 2r - 2)}{(\nu_2 - 2)(\nu_2 - 4) \dots (\nu_2 - 2r)}.$$

În particular, au loc formulele

$$M(X) = \frac{\nu_2}{\nu_2 - 2}; \quad M_2(X) = \frac{\nu_2^2}{\nu_1} \cdot \frac{\nu_1 + 2}{(\nu_2 - 2)(\nu_2 - 4)},$$

valabile pentru $\nu_2 > 2$ și respectiv $\nu_2 > 4$. Dacă $\nu_2 > 4$, atunci

$$D^2(X) = \frac{2\nu_2^2(\nu_1 + \nu_2 - 2)}{\nu_2 - 2}.$$

În figura 6 apare graficul unei densități de probabilitate de tip F .

Cele două teoreme care urmează precizează legătura între distribuția F și alte repartiții.

Teorema 18. Dacă $X_1 \in X^2(\nu_1, \sigma^2)$ și $X_2 \in X^2(\nu_2, \sigma^2)$, atunci variabila aleatoare

$$Y = \frac{\frac{1}{\nu_1} X_1}{\frac{1}{\nu_2} X_2}$$

apartine clasei $F(\nu_1, \nu_2)$.

Demonstrație. Deoarece X_1 și X_2 sunt independente, densitatea de probabilitate a vectorului aleator (X_1, X_2) este

$$f(x_1, x_2) = f_{\chi^2}(x_1; \nu_1, \sigma^2) f_{\chi^2}(x_2; \nu_2, \sigma^2).$$

Densitatea de probabilitate a lui (Y, X_2) se obține observând că

$$x_1 = \frac{\nu_1}{\nu_2} y x_2; \quad x_2 = x_2$$

și deci

$$\frac{D(x_1, x_2)}{D(y, x_2)} = \begin{vmatrix} \frac{\nu_1}{\nu_2} x_2 & \frac{\nu_1}{\nu_2} y \\ 0 & 1 \end{vmatrix} = \frac{\nu_1}{\nu_2} x_2,$$

de unde rezultă

$$f(y, x_2) = f(x_1, x_2) \frac{\nu_1}{\nu_2} x_2 = f_{\chi^2}\left(\frac{\nu_1}{\nu_2} y x_2; \nu_1, \sigma^2\right) f_{\chi^2}(x_2; \nu_2, \sigma^2) \frac{\nu_1}{\nu_2} x_2.$$

De aici deducem că densitatea de probabilitate a lui Y este

$$f(y) = \int_{-\infty}^{\infty} f(y, x_2) dx_2 = \frac{v_1}{v_2} \int_0^{\infty} f_{\chi^2}\left(\frac{v_1}{v_2} y x_2; v_1, \sigma^2\right) f_{\chi^2}(x_2; v_2, \sigma^2) \frac{v_1}{v_2} x_2 dx_2.$$

După efectuarea calculelor se obține $f(y) = f(y; v_1, v_2)$. ■

Din ultima teoremă și din teorema 12 rezultă:

Theorem 19. Dacă $X_1, \dots, X_{v_1}$ și $Y_1, \dots, Y_{v_2}$ sunt variabile aleatoare independente din clasa $N(0, \sigma^2)$, atunci variabila aleatoare

$$Z = \frac{v_2}{v_1} \cdot \frac{X_1^2 + \dots + X_{v_1}^2}{Y_1^2 + \dots + Y_{v_2}^2}$$

este de clasă $F(v_1, v_2)$.




Figura 6: Graficul densității de probabilitate $F(15, 5)$