

# Verificarea ipotezelor statistice<sup>1</sup>

## de I. Văduva

### Notații și noțiuni preliminare

Variabila aleatoare:  $X, Y, U, V, \text{etc.}$ , descrisă de funcție de repartiție. Variabila aleatoare este asociată unei populații statistice; valorile ei corespund indivizilor populației.

*Funcție de repartiție:*  $F(x) = P(X < x)$ .  $P = \text{Probabilitate}$ .

*Repartiție continuă, când există  $F'(x)$ .*

*Densitate de repartiție:*  $f(x) = F'(x)$

$$F(x) = \int_{-\infty}^x f(u) du$$

$$0 \leq F(x) \leq 1, F(-\infty) = 0, F(+\infty) = 1,$$

$$\text{Deci } f(x) \geq 0, \int_{-\infty}^{+\infty} f(u) du = 1$$

$$a, b \in R, a < b \Rightarrow F(a) \leq F(b)$$

*Variabila aleatoare discretă este dată de repartiția sa*

$$X : \begin{pmatrix} a_1, & a_2, & \dots, & a_n \\ p_1, & p_2, & \dots, & p_n \end{pmatrix}, p_i = P(X = a_i), 1 \leq i \leq n, \sum_{i=1}^n p_i = 1.$$

$$F(x) = \sum_{a_i < x} p_i, p_i = \text{probabilitati.}$$

---

<sup>1</sup>Conferință prezentată la deschiderea seminarului științific "Nicolas Georgescu Roegen" al Societății Române de Econometrie, 4 iulie 2012

**Notă.**  $n$  poate fi și  $\infty$ .

**Definiție.** *Selecție (Bernoulliană) de volum  $n$  asupra variabilei aleatoare  $X$  este mulțimea de variabile aleatoare  $\{X_1, X_2, \dots, X_n\}$   $n \in \mathcal{N}$ , independente și identic repartizate ca și  $X$ .*

**Notă.** Selecția este rezultatul unor observații sau măsurători independente (stochastic) efectuate asupra a  $n$  indivizi din populație. Dacă variabilele aleatoare  $X, Y$  au respectiv funcțiile de repartiție  $F, G$ , iar funcția lor comună de repartiție este

$$H(x, y) = P(X < x, Y < y)$$

atunci ele sunt independente dacă  $H(x, y) = F(x)G(y)$ .

**Valori medii. Momente.** Dacă considerăm funcția reală  $\varphi(x)$  măsurabilă (!) atunci numim *valoare medie a variabilei aleatoare*  $\varphi(X)$  mărimea

$$E[\varphi(X)] = \int_{-\infty}^{\infty} \varphi(u)f(u)du$$

când integrala există, iar în cazul discret, dacă  $n = \infty$ ,

$$E[\varphi(X)] = \sum_{i=1}^{\infty} \varphi(a_i)p_i$$

când seria este convergentă.

Cazuri particulare:

*Momente de ordinul  $r, r \in \mathcal{N}$ :*

$$m_r = E[X^r] = \int_{-\infty}^{\infty} x^r f(x)dx, \text{ în cazul continuu}$$

$$m_r = E[X^r] = \sum_{i=1}^{\infty} a_i^r p_r, \text{ in cazul discret.}$$

$m_1 = E[X] = (\text{notat}) = m$  se numește *medie* sau *valoare medie* a lui  $X$ .

*Momente centrate* de ordinul  $r, r \in \mathcal{N}$  :

$$\mu_r = E[(X - m)^r]$$

Momentul centrat de ordinul al doilea se numește *dispersie* sau *varianță* și se notează

$$\sigma^2 = \mu_2 = \text{Var}(X)$$

iar  $\sigma = \sqrt{\sigma^2}$  se numește *abatere medie pătratică* sau *abatere standard* sau *deviație standard*.

**Inegalitatea lui Cebysheff.** Dacă există momentele de ordinul 1 și 2, atunci are loc inegalitatea

$$P(|X - m| \leq t\sigma) \geq 1 - \frac{1}{t^2}, \forall t \in \mathcal{R}^+.$$

**Notă.** Aceasta inegalitate permite determinarea unui interval de *concentrație* al valorilor variabilei aleatoare  $X$ . De ex. dacă  $t = 4$ , atunci în intervalul  $(m - 4\sigma, m + 4\sigma)$  se găsesc peste 94% din valorile variabilei aleatoare  $X$ .

**Cazul multidimensional.**

**Vector aleator:**  $\mathbf{X} = (X_1, X_2, \dots, X_k)'$  = vector coloană de dimensiune  $k$ .

*Funcție de repartiție:*

$$F(\mathbf{x}) = F(x_1, x_2, \dots, X_k) = P(X_1 < x_1, \dots, X_k < x_k)$$

*Densitate de repartiție (cazul continuu) când ea există:*

$$f(\mathbf{x}) = f(x_1, x_2, \dots, x_k) = \frac{\partial^k F(x_1, \dots, x_k)}{\partial x_1 \dots \partial x_k}$$

*Proprietăți:*

$$F(-\infty, \dots, -\infty) = 0, F((\infty, \dots, \infty)) = 1, 0 \leq F(x_1, \dots, x_k) \leq 1$$

$$\forall i, -\infty < a_i < b_i < \infty \Rightarrow F(x_1, \dots, a_i, \dots, x_k) \leq F(x_1, \dots, b_i, \dots, X_k)$$

(adica monotonia crescatoare pe componente).

*Proprietăți ale densității de repartiție:*

$$f(\mathbf{x}) \geq 0, \int_{R^k} f(\mathbf{u}) d\mathbf{u} = 1$$

$$F(\mathbf{x}) = \int_{-\infty}^{\mathbf{x}} f(\mathbf{u}) d\mathbf{u}$$

Fie  $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2)'$ ,  $Dim \mathbf{X}_1 = r$ ,  $Dim \mathbf{X}_2 = s$ ,  $r + s = k$   
 $\mathbf{X}_1, \mathbf{X}_2$  subvectori ai lui  $\mathbf{X}$

*Funcția de repartiție marginală a lui  $\mathbf{X}_1$  este*

$$F_1(\mathbf{x}_1) = F(\mathbf{X}_1, \infty = \mathbf{x}_2)$$

*Densitatea marginală a lui  $\mathbf{X}_1$  este*

$$f_1(\mathbf{x}_1) = \frac{\partial^r F_1(\mathbf{x}_1)}{\partial x_1, \dots, \partial x_r}$$

**Momente:**

$$\forall i, E[X_i] = m_i = \int_{R^k} x_i f(\mathbf{x}) d\mathbf{x} = \int_{-\infty}^{\infty} x_i f_i(x_i) dx_i$$

unde  $f_i(x_i)$  este densitatea marginala a componentei aleatoare  $X_i$  cand integralele există.

**Momentul mixt**

$$m_{ij} = E[X_i X_j] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_i x_j f_{ij}(x_i, x_j) dx_i dx_j$$

$f_{ij}$  = densitate marginala a lui  $(X_i, X_j)'$ .

**Covarianța.** cand există este:

$$\text{cov}(X_i, X_j) = E[(X_i - m_i)(X_j - m_j)] = m_{ij} - m_i m_j = \sigma_{ij}$$

Se observa că  $\text{Var}(X_i) = \text{cov}(X_i, X_i) = \sigma_i^2 = \sigma_{ii}$ .

Inegalitatea lui Schwarz

$$|\sigma_{ij}| \leq \sigma_i \sigma_j.$$

**Coeficientul de corelație al variabilelor aleatoare  $X_i$  și  $X_j$**  este

$$\rho_{ij} = \text{corr}(X_i, X_j) = \frac{\text{cov}(X_i, X_j)}{\sqrt{\text{Var}(X_i)\text{Var}(X_j)}} = \frac{\sigma_{ij}}{\sigma_i \sigma_j}$$

**Notă.** *Ineg. Schwarz*  $\Rightarrow \rho_{ij} \in [-1, 1]$

*Interpretarea lui  $\rho$*  : măsoară gradul de dependență stochastică al variabilelor aleatoare  $X_i$  și  $X_j$ .

**Notații:**

Vectorul valoare medie al lui  $\mathbf{X}$  este  $\mu = (m_1, m_2, \dots, m_k)' = \mathcal{E}(\mathbf{X})$ .

**Matricea de covarianță a vectorului  $\mathbf{X}$**  este

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & , \dots & , \sigma_{1k} \\ . & . & \dots & . \\ \sigma_{k1} & \sigma_{k2} & , \dots & , \sigma_{kk} \end{pmatrix} = \text{Cov}(\mathbf{X}, \mathbf{X}')$$

Este pozitiv definită  $\Sigma \succ 0$ , adică  $\mathbf{x}'\Sigma\mathbf{x} > 0$ , și deci inversabilă.

**Ipoteză statistică.**

$\mathcal{F}$  = multimea funcțiilor de repartiție.

$\mathcal{F}_0 \subset \mathcal{F}$ .

$X$  = variabilă aleatoare  $X \rightsquigarrow F$  = funcție de repartiție.

**Definiție.** *Ipoteză statistică este o afirmație asupra lui  $F$  de forma  $H_0 : F \in \mathcal{F}_0$  ce trebuie verificată cu ajutorul unei selecții de volum  $n$ ,  $X_1, X_2, \dots, X_n$ , dată. (Se mai numeste ipoteza nula!)*

Ipoteză simplă când  $\text{Card}\mathcal{F}_0 = 1$ ; ipoteză compusă, când  $\text{Card}\mathcal{F}_0 > 1$ .

Ipoteza alternativă:  $H_1 : F \in \mathcal{F}_1, \mathcal{F}_1 \subset \mathcal{F}, \mathcal{F}_1 \neq \mathcal{F}_0$ .

Cea mai generală alternativă  $H_1 : F \in \mathcal{F} \setminus \mathcal{F}_0$ .

**Ipoteza parametrică:**  $H_0$  se referă la un parametru al funcției de repartiție. De ex.  $\mathcal{F}_0$  este familia repartițiilor normale  $N(m, \sigma)$  și ipoteza este de forma  $H : m = m_0$  (ipoteză simplă); aici alternativa poate fi simplă de forma  $H_1 : m =$

$m_1, m_1 \neq m_0$ , sau alternativa compusă de forma  $H_1 : m \neq m_0$ . În acest caz ipoteza simplă poate fi de forma  $H_0 : |m - m_0| < \lambda$ , iar alternativa va fi de forma  $H_1 : |m - m_0| \geq \lambda$ . Aici  $m = E[X]$  este *adevărată medie* a variabilei aleatoare  $X$ ,  $m_0$  este o valoare dată (de *referință*), iar  $\lambda > 0$  este *eroarea* cu care apreciem că  $m$  poate fi egal cu  $m_0$ .

**Ipoteză de concordanță:**  $H_0 : F \in \mathcal{F}_0$ , (adică se specifică *tipul* funcției de repartiție (de ex normală exponențială Cauchy, Poisson, binomială etc.) Majoritatea funcțiilor de repartiție depind de *parametri*  $\theta$ , adică  $F(x) = F(x, \theta)$  unde  $\theta$  este un parametru *uni* sau *multidimensional*. Dacă  $\theta$  este cunoscut, atunci ipoteza de concordanță se numește **complet specificată**, iar în caz contrar, se numește **nespecificată**.

**Notă.** Fiind dată o selecție  $\mathbf{X}' = X_1, X_2, \dots, X_n$  de volum  $n$  asupra variabilei aleatoare  $X$ , vectorul  $\mathbf{X}'$  are o repartiție de probabilitate pe  $R^n$ , a cărei densitate  $f$ , (când  $F$  are densitate) este

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

Funcția  $L(x_1, \dots, x_n)$  se numește **funcție de verosimilitate**.

Să mai observăm că  $L(X_1, \dots, X_n)$ , cu argumente  $X_i =$  valori de selecție este o variabilă aleatoare!

**Definiție.** Un **test** de verificare a unei ipoteze statistice, este o regulă prin care spațiul  $R^n$  al selecțiilor se descompune în două părți  $W = R_1^n$ , și  $\bar{W} = R_2^n = R^n \setminus R_1^n$  (complementarul lui  $R_1^n$ ) astfel încât, dacă vectorul de selecție  $\mathbf{X}' \in W$  atunci **se respinge ipoteza**  $H_0$ , (adică se acceptă alternativa  $H_1$ ), iar în caz contrar (adică dacă  $\mathbf{X}' \in \bar{W}$ ,) atunci se acceptă

ipoteza  $H_0$ . Mulțimea  $W = R_1^n$  se numește **domeniu critic al ipotezei  $H_0$** , iar  $\bar{W} = R_2^n$  se numește **domeniu de acceptare al ipotezei  $H_0$** .

**Observație importantă.** Deoarece o selecție de volum finit  $n$  nu asigură o informație completă, **decizia** care se ia pe baza acestei selecții asupra validității sau nu a ipotezei  $H_0$  ne poate conduce la următoarele rezultate: să acceptăm  $H_0$  când ea este adevărată (notată  $(H_0|H_0)$ ), să acceptăm  $H_0$  când ea nu este adevărată (notată  $(H_0|H_1)$ ), să respingem  $H_0$  când ea este adevărată (notată  $(H_1|H_0)$ ) sau să respingem  $H_0$  când ea nu este adevărată (notată  $(H_1|H_1)$ ). Evident, deciziile bune sunt în primul și ultimul caz, pe când celelalte două cazuri constituie **erori ce se comit fiecare cu o probabilitate**. Aceste probabilități sunt

$$\alpha = P(H_1|H_0) = P(\mathbf{X}' \in W|H_0), \beta = P(H_0|H_1) = P(\mathbf{X}' \in \bar{W})$$

$\alpha$  este **probabilitatea erorii de genul întâi sau riscul**, de genul întâi, în timp ce  $\beta$  este **probabilitatea erorii de genul doi sau riscul de genul doi**.  $\alpha$  se mai numește și **prag de semnificație**.

Probabilitatea

$$\pi = P(H_1|H_1) = 1 - \beta$$

se numește **puterea testului**.

Un test bun este acela pentru care  $\alpha$  și  $\beta$  sunt mici (de ex. 0.05 sau mai mici, sau  $\alpha$  este mic și puterea testului  $\pi$  este mare). Din păcate, pentru o selecție de volum  $n$  dată, dacă se impune un risc  $\alpha$  dat, atunci nu există un test pentru care  $\beta$  să fie de asemenea oricât mic. **Testul pentru care la un**



prag de semnificație dat  $\alpha$  există o limitare inferioară a riscului de genul doi  $\beta$  (sau corespunzător există o limitare superioară a lui  $\pi$ ), se numește test uniform cel mai puternic. Existența acestui lucru a este stipulată de următoarea

**Lema lui Neyman-Pearson.** Fie  $X \rightsquigarrow f(x, \theta)$  și fie ipoteza parametrică simplă  $H_0 : \theta = \theta_0$  și alternativa  $H_1 : \theta = \theta_1$ . Atunci pentru un prag  $\alpha$  dat, există un test uniform cel mai puternic a cărui regiune critică este de forma

$$W = \{(X_1, \dots, X_n)' \mid \frac{L_1}{L_0} \geq c > o, \}$$

$c$  este o constantă și unde

$$L_1 = L(X_1, \dots, X_n, \theta_1) = \prod_{i=1}^n f(X_i, \theta_1),$$

$$L_0 = L(X_1, \dots, X_n, \theta_0) = \prod_{i=1}^n f(X_i, \theta_0)$$

, adică  $L_1, L_0$  sunt respectiv funcțiile de verosimilitate ale lui  $X$  în ipotezele  $H_1, H_0$ .

**Definiție.** Numim **statistică** o funcție  $t(X_1, \dots, X_n)$  (care depinde de datele de selecție). Depinzând de repartiția de probabilitate a lui  $X$ , statistica  $t$  are o **repartiție de probabilitate**. Dacă riscul  $\alpha$  este dat atunci, pentru o statistică  $t$  convenabil aleasă se poate construi un test pentru ipoteza  $H_0$  a cărui regiune critica este de forma

$$W_\alpha = \{(X_1, X_2, \dots, X_n)' : P(t(X_1, \dots, X_n) > c_\alpha \mid H_0) = \alpha\},$$

unde repartiția statisticii  $t$  este considerată în ipoteza  $H_0$ . Regiunea critică a testului,  $W_\alpha$ , se numește **regiune critică de nivel  $\alpha$** .

O statistică  $t$  cu ajutorul căreia se construiește un test pentru o ipoteză nulă  $H_0$  se numește **statistică test**.

Din lema lui Neyman-Pearson rezultă că pentru verificarea ipotezei  $H_0$  cu alternativa  $H_1$  **statistica test** este raportul de verosimilități

$$t(X_1, X_2, \dots, X_n, \theta_0, \theta_1) = \frac{L(X_1, \dots, X_n; \theta_1)}{L(X_1, X_2, \dots, X_n; \theta_0)}$$

Testul, se numește **testul raportului de verosimilități**.

**Exemplu.** Fie  $X \rightsquigarrow N(m, \sigma)$  variabila normală, cu abaterea medie pătratică  $\sigma$ , cunoscută. Fie de verificat ipoteza parametrică  $H_0 : m = m_0$  cu alternativa  $H_1 : m = m_1 > m_0$ . (Ambele ipoteze sunt simple). Testul raportului de verosimilități conduce, după calcule, la statistica

$$t = \frac{L_1}{L_0} = e^{\bar{X} \cdot n \left( \frac{m_1 - m_0}{\sigma^2} - \frac{m_1^2 - m_0^2}{2\sigma^2} \right)},$$

unde  $\bar{X}$  este *media aritmetică* a datelor de selecție, sau *media de selecție*.

Regiunea critică de nivel  $\alpha$  se obține din relația

$$P\left(\frac{L_1}{L_0} \geq c\right) = \alpha = P\left(\bar{X} \left( \frac{m_1 - m_0}{\frac{\sigma^2}{n}} - \frac{m_1^2 - m_0^2}{\frac{2\sigma^2}{n}} \right) \geq \log c\right) = \alpha,$$

adică regiunea critică a testului este în final de forma

$$W_\alpha = \{(X_1, \dots, X_n)' : P(\bar{X} \geq \frac{\frac{2\sigma^2}{n} \log c + (m_1^2 - m_0^2)}{2(m_1 - m_0)}) = \alpha\}. \quad (1)$$

Regiunea critică  $W_\alpha$  se poate deduce sub o formă echivalentă astfel. În ipoteza  $H_0$ , statistica

$$U = \frac{\bar{X} - m_0}{\frac{\sigma}{\sqrt{n}}} \rightsquigarrow N(0, 1).$$

Deci, pentru un  $\alpha$  dat, alegem  $z_\alpha$  astfel încât

$$P(Z \geq z_\alpha) = \int_{z_\alpha}^{\infty} e^{-\frac{t^2}{2}} dt = \alpha,$$

de unde domeniul critic este

$$W_\alpha = \{(X_1, X_2, \dots, X_n)' | \bar{X} \geq m_0 + \frac{z_\alpha}{\sqrt{n}}\}. \quad (2)$$

Mărimea  $z_\alpha$  se numește  $\alpha$ -cuantila superioară a repartiției normale  $N(0, 1)$ .

Observăm că cele două forme ale domeniului critic  $W_\alpha$  date de (1) și (2) coincid, deoarece au același nivel  $\alpha$ .

**Puterea testului**, este

$$\begin{aligned} \pi(m_1) &= P(\bar{X} \geq m_0 + z_\alpha \frac{\sigma}{\sqrt{n}} | H_1) = P\left(\frac{\bar{X} - m_1}{\frac{\sigma}{\sqrt{n}}} \geq \frac{m_0 - m_1}{\frac{\sigma}{\sqrt{n}}} + z_\alpha\right) = \\ &= P\left(Z \geq \frac{m_0 - m_1}{\frac{\sigma}{\sqrt{n}}} + z_\alpha\right) \end{aligned}$$

Deoarece  $\pi(m_1) = 1 - \beta$  rezultă că

$$1 - \phi\left(z_\alpha + \frac{\sigma}{\sqrt{n}}\right) = 1 - \beta$$

deci

$$z_\alpha + \frac{m_0 - m_1}{\frac{\sigma}{\sqrt{n}}} = z_{1-\beta}$$

Ultima formulă conduce la faptul că dacă se dau riscurile  $\alpha$  și  $\beta$  atunci volumul **minim** de selecție necesar pentru realizarea acestor riscuri este

$$n = (z_{1-\beta} - z_\alpha)^2 \frac{\sigma^2}{(m_1 - m_0)^2}$$

ceea ce conduce si la o altă consecință a lemei Neyman-Pearson.

**Notă.** Din cele de mai sus, observăm că dacă considerăm parametrul  $\lambda = |m_0 - m_1|$  ca o **distanță** între ipotezele  $H_0$  și  $H_1$  și considerăm că pentru o distanță  $\lambda_0$  dată  $H_1 \sim H_0$  atunci puterea  $\pi$  se exprimă în funcție de  $\lambda$  și anume

$$\pi(\lambda) = 1 - \phi\left(z_\alpha + \frac{\lambda}{\sigma\sqrt{n}}\right).$$

### Forma generală a testului raportului de verosimilități.

Să considerăm ipoteza  $H : F \in \omega \subset \Omega$ , unde  $\Omega$  este o clasă de funcții de repartiție și  $\omega$  o submulțime a sa. Alternativa este  $\mathcal{N}H : F \in \Omega \setminus \omega$ . Să notăm  $(L)_\Omega, (L)_\omega$  **valorile maxime** ale funcției de verosimilitate în ipotezele  $\Omega, \omega$  și să considerăm **raportul de verosimilitate**

$$\Lambda(\mathbf{X}) = \frac{(L)_\omega}{(L)_\Omega}, \mathbf{X} = \text{vectorul de selecție.}$$

Deoarece  $\omega \subset \Omega$  rezultă că  $\Lambda(\mathbf{X}) \leq 1$ , iar când  $\omega$  este adevărată,  $\Lambda(\mathbf{X}) = 1$ . (Caz ideal!).

Deci domeniul critic pentru testarea ipotezei  $H$  este de forma

$$W(c) = \{\mathbf{X} | \Lambda(\mathbf{X}) \leq c < 1\}, P(\Lambda(\mathbf{X}) \leq c) = \alpha. \quad (3)$$

**Lema lui Neyman-Pearson** este valabilă și aici; regiunea critică  $W(c)$  dată de (3) corespunde **testului uniform cel mai puternic**.

Pentru a construi testul raportului de verosimilități pentru o ipoteză  $H$  va trebui mai întâi să calculăm valorile maxime  $(L)_\Omega, (L)_\omega$  ale funcției de verosimilitate.

**Exemplu.** Fie  $X \rightsquigarrow N(m, \sigma)$  cu  $\sigma$ -cunoscut și fie de verificat ipoteza  $H : m = m_0$  cu alternativa  $\mathcal{N}H : m \neq m_0$ . Maximul funcției de verosimilitate în ipoteza  $\Omega$  conduce la

$$(L)_\Omega = \left( \frac{1}{2\pi\sigma^2} \right)^{\frac{n}{2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2}$$

iar

$$(L)_\omega = \left( \frac{1}{2\pi\sigma^2} \right)^{\frac{n}{2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - m_0)^2}.$$

Raportul de verosimilități este

$$\Lambda(\mathbf{X}) = e^{-\frac{n}{2\sigma^2}(\bar{X} - m_0)^2}$$

iar domeniul critic este de forma (3) unde  $c = c_\alpha$  satisface relația

$$\alpha = P\left[-\frac{n}{2\sigma^2}(\bar{X} - m_0)^2 \leq \log c_\alpha\right] = P\left[\left|\frac{\bar{X} - m_0}{\frac{\sigma}{\sqrt{n}}}\right| \geq \sqrt{-2 \log c_\alpha}\right].$$

Deoarece

$$\frac{\bar{X} - m_0}{\frac{\sigma}{\sqrt{n}}} = Z \rightsquigarrow N(0, 1)$$

rezultă că folosind  $z_{\frac{\alpha}{2}}$  dat de relația

$$\int_{-z_{\frac{\alpha}{2}}}^{z_{\frac{\alpha}{2}}} e^{-\frac{u^2}{2}} du = 1 - \alpha,$$

domeniul critic este de forma

$$W_\alpha = \left\{ \mathbf{X}' : \left| \frac{\bar{X} - m_0}{\frac{\sigma}{\sqrt{n}}} \right| \geq z_{\frac{\alpha}{2}} \right\}. \quad (3')$$

Puterea testului  $\pi(m)$  se calculează cu formula

$$P\left(\left|\frac{\bar{X} - m_0}{\frac{\sigma}{\sqrt{n}}}\right| \geq z_{\frac{\alpha}{2}} | \mathcal{N}H\right) = \pi(m). \quad (4)$$

Testul prezentat se numeste testul  $U$ .

### Problema celor două selecții.

Fie  $X \rightsquigarrow N(m_1, \sigma_1)$ ,  $Y \rightsquigarrow N(m_2, \sigma_2)$  cu  $\sigma_1, \sigma_2$  cunoscute. Se dă o selecție de volum  $n_1$  pentru  $X$  și o selecție de volum  $n_2$  pentru  $Y$ . Pentru verificarea ipotezei  $H : m_1 = m_2$  cu alternativa  $\mathcal{N}H : m_1 \neq m_2$  se folosește statistica

$$U = \frac{\bar{X} - \bar{Y} - m_1 + m_2}{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}. \quad (5)$$

care în ipoteza  $H$  are repartiția normală  $N(0, 1)$ .

Domeniul critic se determină pe baza statisticii  $U$  dată de (5) și el este de forma

$$W_\alpha = \{\mathbf{X}' : |U| \geq z_{\frac{\alpha}{2}}\},$$

iar Puterea testului se calculează cu formula

$$\pi(m_1 - m_2) = P(|U| \geq z_{\frac{\alpha}{2}} | \mathcal{N}H).$$

### Cazul dispersiilor necunoscute. Repartiții înrudite cu repartițiile normale.

Fie de testat  $H : m = m_0$ ,  $\mathcal{N}H : m \neq m_0$ , cu  $\sigma$  necunoscut. Determinarea raportului de verosimilități, conduce mai întâi la estimarea lui  $m$  cu  $\bar{X}$  și a lui  $\sigma^2$  cu formula

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (6)$$

după care se calculează  $(L)_\Omega$  și  $(L)_\omega$

In final testul raportului de verosimilități conduce la **statistica  $t$  a lui Student**, adică

$$t = \frac{\bar{X} - m_0}{\frac{s}{\sqrt{n}}} \quad (6')$$

care in ipoteza  $H$  are **repartiția Student cu  $f = n - 1$  grade de libertate**, ce are densitatea de repartiție

$$g(x) = \frac{1}{\sqrt{\pi}} \frac{\Gamma(\frac{f+1}{2})}{\Gamma(\frac{f}{2})} \frac{1}{(1+x^2)^{\frac{f+1}{2}}}. \quad (7)$$

Variabila Student se definește cu formula

$$t_f = \frac{Z}{\frac{\chi_f}{\sqrt{f}}}, t_f \in R, Z \rightsquigarrow N(0, 1)$$

unde  $\chi_f^2 = \sum_{i=1}^f Z_i^2$ , iar  $Z_i$  sunt variabile  $N(0, 1)$  independente și  $Z$  e independent de  $\chi_f^2$ .

Densitatea de repartiție a lui  $\chi_f^2$  este

$$h(x) = \frac{1}{2^{\frac{f}{2}} \Gamma(\frac{f}{2})} x^{\frac{f}{2}-1} e^{-\frac{x}{2}}, x > 0, h(x) = 0 \text{ daca } x \leq 0. \quad (8)$$

Dacă  $E[Z_i] = m_i \neq 0$  măcar pentru un  $i$  atunci

$$\sum_{i=1}^f Z_i^2 = \chi_{f,\delta}^2$$

cu  $\delta^2 = \sum_{i=1}^f m_i^2$  se numește **variabilă  $\chi^2$  necentrată, cu  $f$  grade de libertate și cu parametru de excentricitate  $\delta$** .

Nu precizăm densitatea de repartiție (complicată!) a acestei variabile.

**Definiție.** Variabila aleatoare  $F_{f_1, f_2} > 0$  este definită astfel

$$F_{f_1, f_2} = \frac{f_2 \chi_{f_1}^2}{f_1 \chi_{f_2}^2}, \quad (9)$$

Variabila  $F_{f_1, f_2}$  are o densitate de repartiție pe care nu o prezentăm aici. Sunt utilizate și variabile  $F$  necentrate de forma

$$F_{f_1, f_2; \delta_1, 0}, F_{f_1, f_2; 0, \delta_2}, F_{f_1, f_2; \delta_1, \delta_2}.$$

Cea mai utilizată după cum vom vedea, este prima formă de  $F$ -necentrata.

Între variabila  $F$  și variabila  $t$  este valabilă relația

$$t_f^2 = F_{1, f}.$$

### Forme ale testului $t$ .

Pentru un risc  $\alpha$  dat, să considerăm cuantila superioară  $t_{f, \frac{\alpha}{2}} > 0$  care satisface relația

$$P(|t_f| \leq t_{f, \frac{\alpha}{2}}) = \int_{t_{f, \frac{\alpha}{2}}}^{t_{f, \frac{\alpha}{2}}} g(u) du = 1 - \alpha \quad (10)$$

Ca și testul  $U$ , testul  $t$ , dedus din testul general al raportului de probabilități, capătă forme asemănătoare, după cum urmează:

t1. **Verificarea ipotezei**  $H : m = m_0, \sigma - necunoscut$ , **cu alternativa**  $\mathcal{N}H : m \neq m_0$ . Domeniul critic este

$$\left| \frac{\bar{X} - m_0}{\frac{s}{\sqrt{n}}} \right| \geq t_{f, \frac{\alpha}{2}}, f = n - 1, \quad (11)$$



Puterea testului se calculează cu formula

$$\pi(m) = P\left(\left|\frac{\bar{X} - m_0}{\frac{s}{\sqrt{n}}}\right| \geq t_{f, \frac{\alpha}{2}} \mid : \mathcal{NH}\right) \quad (11')$$

unde statistica din formulă are repartiția  $t$ -necentrată adică

$$t_{f, \delta}^2 = F_{1, f; \delta, 0}, \delta^2 = \left(\frac{m_1 - m_0}{\frac{s}{\sqrt{n}}}\right)^2. \quad (11'')$$

**t2. Verificarea ipotezei  $H : m_1 = m_2$  pentru două populații  $N(m_1, \sigma), N(m_2, \sigma), \sigma$  – cunoscut cu  $\mathcal{NH} : m_1 \neq m_2$ .** Fie  $X \rightsquigarrow N(m_1, \sigma_1), Y \rightsquigarrow N(m_2, \sigma_2)$   $\sigma_1 = \sigma_2 = \sigma$ . și volumele de selecție  $n_1, n_2$ . Dispersia  $\sigma^2$  se estimează astfel

$$s^2 = \frac{1}{n_1 + n_2 - 2} \left\{ \sum_{i=1}^{n_1} (X_i - \bar{X})^2 + \sum_{j=1}^{n_2} (Y_j - \bar{Y})^2 \right\}, f = n_1 + n_2 - 2.$$

Statistica  $t$  este în acest caz

$$t = \frac{\bar{X} - \bar{Y}}{s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

domeniul critic de nivel  $\alpha$  este de forma (11), iar puterea testului  $\pi(m_1 - m_2)$  este de forma (11') cu

$$\delta^2 = \left( \frac{m_1 - m_2}{s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \right)^2.$$

**t3. Verificarea ipotezei  $H$  din cazul precedent, cu  $\sigma_1, \sigma_2$  necunoscute și ne egale.** În acest caz testul  $t$  are o construcție specială și anume;

- se estimează dispersiile cu formulele obișnuite

$$s_1^2 = \frac{1}{f_1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2, f_1 = n_1 - 1; s_2^2 = \frac{1}{f_2} \sum_{j=1}^{n_2} (Y_j - \bar{Y})^2, f_2 = n_2 - 1; \quad (12)$$

- se calculează gradele de libertate  $f$  cu formulele

$$c = \frac{\frac{s_1^2}{f_1}}{\frac{s_1^2}{f_1} + \frac{s_2^2}{f_2}}$$

$$f = \frac{1}{\frac{c^2}{f_1} + \frac{(1-c)^2}{f_2}}$$

( $f$  este rotunjit la întreg)

- statistica  $t$  este

$$t = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

În continuare testul  $t$  se dezvoltă ca la  $t_2$ .

### **Teste privind egalitatea dispersiilor populațiilor normale.**

Se dau  $X \rightsquigarrow N(m_1, \sigma_1), Y \rightsquigarrow M(m_2, \sigma_2)$  și selecțiile independente corespunzătoare de volume  $n_1, n_2$ . Ipoteza  $H : \sigma_1 = \sigma_2$  cu alternativa  $\mathcal{N}H : \sigma_1 \neq \sigma_2$  se verifică folosind testul  $F$  (al lui Snrdrcor) după cum urmează:

- se estimează  $\sigma_1^2, \sigma_2^2$  cu formulele (12);

se calculează statistica

$$F = \frac{s_1^2}{s_2^2}$$

Statistica  $F$  are repartiția  $F$ -centrată cu  $(f_1, f_2)$  grade de libertate. Deci **domeniul critic de nivel  $\alpha$**  este

$$F \geq F_{f_1, f_2; \alpha}, \text{ unde } P(F_{f_1, f_2} \geq F_{f_1, f_2; \alpha}) = \alpha,$$

adică  $F_{f_1, f_2; \alpha}$  este  $\alpha$ -cuantila superioară a repartiției  $F$ .

**Testul lui Bartlett pentru egalitatea a mai multe dispersii.** Se dau  $k$  populații normale  $N(m_1, \sigma_i), 1 \leq i \leq k$  și selecții corespunzătoare  $X_{i,j}, 1 \leq i \leq k, 1 \leq j \leq n_i$  de volume  $n_1, n_2, \dots, n_k, n_i > 3$  respectiv. Se cere să se verifice ipoteza

$$K : \sigma_1^2 = \dots = \sigma_k^2.$$

Testul lui Bartlett se realizează în următorii pași:

- se estimează dispersiile cu formulele

$$S_i^2 = \frac{1}{n_i - 1} \left( \sum_{j=1}^{n_i} X_{ij}^2 - n_i \bar{X}_i^2 \right), 1 \leq i \leq k$$

- se calculează  $s^2$  cu formula

$$s^2 = \frac{1}{f} \left( \sum_{i=1}^k f_i s_i^2 \right), f_i = n_i - 1, f = \sum_{i=1}^k f_i$$

se calculează statistica lui Bartlett

$$\chi^2 = -\frac{1}{B} \sum_{i=1}^k f_i \log \frac{s_i^2}{s^2}, B = \frac{\sum_{i=1}^k \frac{1}{n_i - 1} - \frac{1}{n - k}}{3(k - 1)} + 1, n = \sum_i n_i. \quad (13)$$

Statistica  $\chi^2$  are  $k - 1$  grade de libertate, deci domeniul critic al testului lui Bartlett este

$$\chi^2 \geq \chi_{k-1, \alpha}^2, \text{ unde } P(\chi_{k-1}^2 \geq \chi_{k-1, \alpha}^2) = \alpha.$$

(aici  $\alpha$  este riscul de genul intai).

Puterea testului se calculează pe baza repatriției necentrate

$$\chi_{k-1,\delta}^2, \delta^2 = \frac{\sum_{i=1}^k f_i \sigma_i^2}{f},$$

( $\sigma_i$  diferite între ele).

**Teste de concordanță.** Presupunem că se dă o selecție de volum  $n$  asupra lui  $X$  și se cere să verificăm ipoteza de concordanță  $H : X \rightsquigarrow F$ . Prezentăm două teste **asimptotice** (când  $n \rightarrow \infty$ ).

**Testul de concordanță  $\chi^2$ .**

Dacă ipoteza  $H$  este **complet specificată**, atunci testul  $\chi^2$  constă din următoarele etape:

- se consideră  $0$  diviziune a mulțimii  $\Delta$  pe care variabila aleatoare  $X$  ia valori de probabilități pozitive, adică

$$\Delta = \bigcup_{i=1}^k \Delta_i, \Delta_i \cap \Delta_j = \emptyset, P(\Delta_i) > 0.$$

- se calculează probabilitățile  $p_i = P(\Delta_i) > 0, 1 \leq i \leq k$ ;

- pentru selecția dată  $X_1, X_1, \dots, X_n, n = f.mare(n > 1000)$  se determină  $f_i =$  **numărul valorilor de selecție ce aparțin lui  $\Delta_i$ , adică frecvențele absolute pe  $\Delta_i$** ;

- se calculează statistica

$$\chi^2 = \sum_{i=1}^k \frac{(f_i - np_i)^2}{np_i} \quad (13 - 1)$$

Deoarece statistica  $\chi^2$  are repartiția  $\chi_{k-1}^2$ , domeniul critic al testului este

$$\chi^2 \geq \chi_{k-1,\alpha}^2, P(\chi_{k-1}^2 \geq \chi_{k-1,\alpha}^2) = \alpha.$$

Puterea testului se determină ca de obicei cu  $\chi^2$  necentrat (repartiția statisticii (13-1) în ipoteza  $\mathcal{NH}$ .)

**Dacă  $H$  este nespecificată,** atunci etapele testului  $\chi^2$  suferă o modificare și anume dacă funcția de repartiție depinde de un parametru  $\theta = (\theta_1, \dots, \theta_c)'$ ,  $c < k - 1$ , atunci  $p_i = p_i(\theta)$  și statistica (13-1) devine

$$\chi^2(\theta) = \sum_{i=1}^k \frac{(f_i - np_i(\theta))^2}{np_i(\theta)} \quad (13 - 2)$$

iar parametrul  $\theta$  trebuie estimat. Estimația  $\bar{\theta}$  se obține minimizând (13-2) în raport cu **theta**, dar cu condiția ca numitorii din suma (13-2) să fie asimptotic constanți. (Această metodă de estimare se numește **metoda minimului lui  $\chi^2$  modificat.**) După estimarea celor  $c$  parametri, probabilitățile din (13-1) devin  $p_i = \hat{p}_i = p_i(\bar{\theta})$ , iar statistica devine

$$\chi^2(\bar{\theta}) = \sum_{i=1}^k \frac{(f_i - n\hat{p}_i)^2}{n\hat{p}_i}. \quad (13 - 3)$$

Se știe că statistica (13-3) are o repartiție  $\chi^2_{k-c-1}$  și de aici se continuă pașii din cazul când  $H$  este complet specificată. Puterea testului se calculează tot cu  $\chi^2$ -necentrat unde parametrul de excentricitate este

$$\delta^2 = \sum_{i=1}^k \frac{(p_i^H - p_i^{NH})^2}{np_i^H},$$

unde  $p_i^H, p_i^{NH}$  sunt calculate în ipotezele respective.

### **Teste de concordanță de tip Kolmogorov-Smirnov.**

Aceste teste se aplică numai când funcția de repartiție  $F$  este continuă.

Definim mai întâi **estimația nedeplasată a funcției de repartiție**  $F(x)$ . Aceasta este

$$F_n(x) = \frac{\nu(x)}{n}, \quad (13 - 4)$$

unde  $\nu(x)$  = **numărul valorilor de selecție mai mici decât**  $X$ . Ea se mai numește și **funcția de repartiție empirică**.

Să notăm

$$D_n = \sup_x |F(x) - F_n(x)| = \max_{1 \leq i \leq n} |F(X_i) - F_n(X_i)|$$

$$D_n^+ = \max_{1 \leq i \leq n} [F_n(X_i) - F(X_i)], \quad D_n^- = \max_{1 \leq i \leq n} [F(X_i) - F_n(X_i)].$$

Testele de tip Kolmogorov-Smirnov se bazează pe următoarele teoreme limită:

**Teorema lui Kolmogorov.** Dacă  $F$  este continuă, atunci

$$\lim_{n \rightarrow \infty} P(D_n < \frac{\lambda}{\sqrt{n}}) = \sum_{k=-\infty}^{+\infty} (-1)^k e^{-\lambda^2 k^2} = K(\lambda). \quad (13 - 5)$$

**Teorema lui Smirnov.** Dacă  $F$  este continuă atunci

$$\lim_{n \rightarrow \infty} P(D_n^+ < \frac{\lambda}{\sqrt{n}}) = 1 - e^{-2\lambda^2}. \quad (13 - 6)$$

**Testul lui Kolmogorov** are domeniul critic de nivel  $\alpha \leq 0.05$  de forma

$$D_n > \frac{\lambda_\alpha}{\sqrt{n}}, \quad \text{unde } K(\lambda_\alpha) = 1 - \alpha. \quad (13 - 7)$$

În mod asemănător, domeniul critic pentru **testul lui Smirnov** este

$$D_n^+ > \frac{\theta_\alpha}{\sqrt{n}}, \quad \text{unde } e^{-2\theta_\alpha^2} = \alpha. \quad (13 - 8)$$

Puterea testului Kolmogorov se calculează pe baza repartiției asimptotice a statisticii

$$D_n^* = \sup_x |F_n(x) - G(x)|, \text{ unde } \mathcal{N}H : X \rightsquigarrow G(x).$$

Nu există evaluări exacte privind puterea testului lui Kolmogorov.

**Dacă** pentru două variabile  $X$  având funcția de repartiție  $F$  și  $Y$  având funcția de repartiție  $G$  ( $F, G$  necunoscute!), se dau două selecții asupra lor, de volume  $n$  și  $m$  respectiv, atunci se poate pune problema **testării ipotezei**  $H : F = G$ . Testarea acestei ipoteze se face pe baza următoarei teoreme

**Teorema lui Smirnov.** Dacă  $F$  și  $G$  sunt continue și notăm

$$D_{n,m} = \sup_x |F_n(x) - G_m(x)|,$$

atunci

$$\lim_{n,m \rightarrow \infty, \frac{n}{m} = \rho = \text{const.}} P(D_{n,m} < \lambda \sqrt{\frac{1}{n} + \frac{1}{m}}) = K(\lambda). \quad (13 - 9)$$

Domeniul critic al testului este

$$D_{n,m} > \lambda_\alpha \sqrt{\frac{1}{n} + \frac{1}{m}}, \quad K(\lambda_\alpha) = 1 - \alpha. \quad (13 - 10)$$

Puterea testului se determină ca și în cazul testului Kolmogorov.

### Teste pentru repartiții multidimensionale.

Vom prezenta teste referitoare la mediile **repartițiilor normale multidimensionale**. Vectorul  $\mathbf{X} = (X_1, X_2, \dots, X_k)'$  are repartiția normală  $k$ -dimensională  $N(\mu, \Sigma)$  dacă densitatea sa de repartiție este

$$f(\mathbf{x}, \mu, \Sigma) = \frac{1}{(2\pi)^{\frac{k}{2}} \det(\Sigma)^{\frac{1}{2}}} e^{-\frac{1}{2}(\mathbf{x}-\mu)'\Sigma^{-1}(\mathbf{x}-\mu)}. \quad (14)$$

$\mu$  este vectorul medie al lui  $\mathbf{X}$ , iar  $\Sigma$  este matricea de covarianță a lui  $\mathbf{X}$  notate respectiv

$$\mu = \mathcal{E}(\mathbf{X}), \Sigma = \text{Cov}(\mathbf{X}, \mathbf{X}'),$$

vectorii, fiind vectori coloană, iar produsele matriceale sunt calculate conform regulii obișnuite "linii prin coloane". Matricea  $\Sigma$  este pozitiv definită, (notată  $\Sigma \succ 0$ ), de unde rezultă că **forma pătratică** de la exponent in formula (14) este **pozitiv definită**. O selecție de volum  $N$  asupra vectorului aleator  $\mathbf{X}$  este de forma  $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N$  care de fapt este o matrice  $N \times k$ ,  $\mathbf{X}_i$  fiind coloanele acestei matrici:  $\mathbf{X}_i$  sunt deci **valori de selecție efectuate asupra lui  $\mathbf{X}$** .

Estimațiile **nedeplasate** ale parametrilor  $\nu, \Sigma$  sunt respectiv

$$\bar{\mathbf{X}} = \sum_{i=1}^N \mathbf{X}_i, S = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})', \quad (16)$$

adică

$$\mathcal{E}[\bar{\mathbf{X}}] = \mu, \mathcal{E}[S] = \Sigma.$$

In cazul unidimensional testele asupra mediilor se bazează pe statistica  $U$  repartizată normal și pe statistica  $t$  a lui Student. Asemănător, testele privind mediile repartițiilor normale multi dimensionale se vor baza pe o **statistică**  $\chi^2$  și pe o statistică  $T^2$  a lui Hotelling, cu  $n$  grade de libertate. Aceste statistici arată de forma

$$\chi_k^2 = \mathbf{Y}'\Sigma^{-1}\mathbf{Y}, \mathbf{Y} \rightsquigarrow N(\mathbf{0}, \Sigma), \quad (17)$$

$$T_n^2 = \mathbf{Y}'S^{-1}\mathbf{Y}, \mathbf{Y} \rightsquigarrow N(\mathbf{0}, \Sigma), nS = \sum_{i=1}^n \mathbf{Z}_i\mathbf{Z}_i', \quad (18)$$

unde  $\mathbf{Z}_i \rightsquigarrow N(\mathbf{0}, \sigma)$ ,  $\mathbf{Z}_i \text{ ind } \mathbf{Y}$ .  $S$  este o matrice *Wishart*. Variabila  $T_n^2$  are **repartiția Hotelling cu  $n$  grade de libertate**.



Se arată că variabila  $T_n^2$  este legată de variabila  $F$  prin relația

$$\frac{n-k+1}{k} \frac{T_n^2}{n} = F_{k, n-k+1}. \quad (18)'$$

iar dacă în (18)  $\mathbf{Y} \rightsquigarrow N(\mu, \Sigma)$ , atunci  $T_n^2$  din (18) are repartiția **Hotelling necentrată** cu parametrul de excentricitate

$$\delta^2 = \mu' \Sigma^{-1} \mu,$$

relația (18') rămânând valabilă și pentru variabile necentrate. Relația (18') se păstrează și între cuantilele variabilelor  $F$  și  $T^2$  și anume

$$T_{n,\alpha}^2 = \frac{nk}{n-k+1} F_{k, n-k, \alpha}. \quad (18'')$$

**Verificarea ipotezelor asupra mediilor când matricile de covarianță sunt cunoscute.**

$\mathbf{H}_1$ . Ipoteza  $H : \mu = \mu_0$ , cu alternativa  $\mathcal{N}H; \mu \neq \mu_0$ . Se folosește selecția de volum  $N$ . Deoarece în ipoteza,  $H \bar{X} \rightsquigarrow N(\mu_0, \frac{\Sigma}{N})$ , rezultă că statistica

$$\chi^2 = N(\bar{\mathbf{X}} - \mu_0)' \Sigma^{-1} (\bar{\mathbf{X}} - \mu_0) \quad (19)$$

are repartiția  $\chi_k^2$ , deci domeniul critic de nivel  $\alpha$  este conform (19)

$$\chi^2 \geq \chi_{k,\alpha}^2, \text{ unde } P(\chi_k^2 \geq \chi_{k,\alpha}^2) = \alpha. \quad (19')$$

Puterea testului este dată de repartiția  $\chi^2$ -necentrată adică

$$\pi(m) = P(\chi_{k;\delta} \geq \chi_{k,\alpha}^2), \text{ unde } \delta^2 = N(\mu - \mu_0)' \Sigma^{-1} (\mu - \mu_0). \quad (20)$$

Amintim faptul că **distanța lui Mahalanobis** dintre repartițiile normale  $N(\mu_1, \Sigma), N(\mu_2, \Sigma)$  este

$$D^2 = (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)$$

deci  $\delta^2$  este o distanță Mahalanobis.

**$H_2$ . Problema celor două selecții, pentru două populații normale  $\mathbf{X} \rightsquigarrow N(\mu_1, \Sigma)$ ,  $\mathbf{Y} \rightsquigarrow N(\mu_2, \Sigma)$  cu  $\Sigma$  cunoscut.**

Presupunem că volumele celor două selecții sunt  $N_1$  respectiv  $N_2$  și avem de testat ipoteza  $H : \mu_1 = \mu_2$  cu alternativa  $\mathcal{N}H : \mu_1 \neq \mu_2$ . Deoarece în ipoteza  $H$  avem

$(\bar{X} - \bar{Y}) \rightsquigarrow N(\mathbf{0}, (\frac{1}{N_1} + \frac{1}{N_2})\Sigma)$ , rezultă

$$\chi^2 = \frac{N_1 N_2}{N_1 + N_2} (\bar{\mathbf{X}} - \bar{\mathbf{Y}})' \Sigma^{-1} (\bar{\mathbf{X}} - \bar{\mathbf{Y}}) \quad (21)$$

Domeniul critic de nivel  $\alpha$  este deci de forma (19') iar puterea testului se determină cu  $\chi^2$ -necentrat cu parametrul de excentricitate

$$\delta^2 = \frac{N_1 N_2}{N_1 + N_2} (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2). \quad (21')$$

**$H_3$ . Problema celor  $r$  selecții.** Fie vectorii normali  $\mathbf{X}^{(i)} \rightsquigarrow N(\mu^{(i)}, \Sigma)$ ,  $\Sigma$  – cunoscut și selecțiile de volume  $N_i$  asupra lor,  $1 \leq i \leq r$ . Se dau constantele  $\beta_i, 1 \leq i \leq r$  (ce pot fi numite **măsurile de ponderare**).

Se cere să se verifice ipoteza  $H : \mu = \mu_0$ ,  $\mu = \sum_{i=1}^r \beta_i \mu_i$ , numită problema celor  $r$  selecții. (În biologie  $\mu$  este media caracteristicii unei specii ce provine din  $r$  ascendenți; în economie,  $\mu$  poate fi suma cheltuită de o familie pentru a-și asigura  $r$  resurse necesare).

Deoarece în ipoteza  $H$  vectorul aleator  $\sum_{i=1}^r \beta_i \bar{\mathbf{X}}^{(i)} \rightsquigarrow N(\mu_0, (\sum_{i=1}^r \frac{\beta_i^2}{N_i})\Sigma)$ , rezultă ca testul se bazează pe statistica

$$\chi^2 = \left( \sum_{i=1}^r \frac{\beta_i^2}{N_i} \right)^{-1} \left( \sum_{i=1}^r \beta_i \bar{\mathbf{X}}^{(i)} - \mu_0 \right)' \Sigma^{-1} \left( \sum_{i=1}^r \beta_i \bar{\mathbf{X}}^{(i)} - \mu_0 \right). \quad (22)$$

Domeniul critic de nivel  $\alpha$  este tot de forma (19') cu  $\chi^2$  dat de (22). Puterea testului se calculează tot cu  $\chi^2$  necentrat cu parametrul de excentricitate

$$\delta^2 = \left( \sum_{i=1}^r \frac{\beta_i^2}{N_i} \right)^{-1} \left( \sum_{i=1}^r \beta_i \mu^{(i)} - \mu_0 \right)' \Sigma^{-1} \left( \sum_{i=1}^r \beta_i \mu_i - \mu_0 \right). \quad (22')$$

**$H_4$ . Cazul matricilor de covarianță neegale.** Dacă  $\mathbf{X}^{(i)} \rightsquigarrow N(\mu_i, \Sigma_i)$ , nu implică dificultăți. In acest caz vectorul  $\sum_{i=1}^r \beta_i \overline{\mathbf{X}^{(i)}} \rightsquigarrow N(\mu, \Sigma_*)$  unde

$$\mu = \sum_{i=1}^r \beta_i \mu_i, \quad \Sigma_* = \left( \sum_{i=1}^r \frac{\beta_i^2}{N_i} \right) \Sigma. \quad (23)$$

Statistica testului este in acest caz

$$\chi^2 = \left( \sum_{i=1}^r \beta_i \overline{\mathbf{X}^{(i)}} - \mu_0 \right)' \Sigma_*^{-1} \left( \sum_{i=1}^r \beta_i \overline{\mathbf{X}^{(i)}} - \mu_0 \right), \quad (23')$$

care are repartiția  $\chi_k^2$ , deci domeniul critic este de forma (19'), iar puterea testului se determină cu  $\chi^2$  necentrat cu parametrul de excentricitate

$$\delta^2 = (\mu - \mu_0)' \Sigma_*^{-1} (\mu - \mu_0). \quad (23'')$$

**$H_5$ . Problema simetriei.** Fie  $X \rightsquigarrow N(\mu, \Sigma)$ ,  $\mu = (\mu_1, \dots, \mu_k)'$ . **Problema simetriei** constă in a verifica ipoteza  $H : \mu_1 = \dots = \mu_k$ .

Fie  $\epsilon = (1, 1, \dots, 1)'$  vectorul  $k$ -dimensional cu toate componentele 1. Să considerăm o matrice  $C^{k \times (k-1)}$ , astfel încât  $C\epsilon = \mathbf{0}$ . O astfel de matrice există deoarece cele  $k \times (k-1)$  elemente ale ei satisfac numai  $k$  ecuații. Cu aceste notații ipoteza  $H$  se poate

scrie  $H : C\mu = \mathbf{0}$ . Deoarece  $\bar{\mathbf{X}}$  este o estimatie a lui  $\mu$ , rezultă că **statistica test**

$$\chi^2 = N(C\bar{\mathbf{X}})'(C\Sigma C')^{-1}(C\bar{\mathbf{X}}) \quad (24)$$

are repartiția  $\chi_{k-1}^2$  și deci domeniul critic

$$\chi^2 \geq \chi_{k-1,\alpha}^2,$$

iar puterea testului este

$$\pi = P(\chi_{k-1;\delta}^2 \geq \chi_{k-1,\alpha}^2), \text{ unde } \delta^2 = N(C\mu)'(C\Sigma C')^{-1}(C\mu). \quad (24')$$

**Teste asupra mediilor repartițiilor normale  $k$ -dimensionale, când matricile de covarianță sunt necunoscut.**

$T_1$ . **Verificarea ipotezei  $H : \mu = \mu_0$  cu alternativa  $\mathcal{N}H : \mu \neq \mu_0$ , cu  $\Sigma$ -necunoscut.**

Cu ajutorul selecției de volum  $N$  se estimează  $\mu$  și  $\Sigma$  astfel

$$\bar{\mathbf{X}} = \frac{1}{N} \sum_{i=1}^N \mathbf{X}_i, S = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})'. \quad (25)$$

Matricea  $S$  fiind o matrice Wishart, rezultă că statistica

$$T^2 = N(\bar{\mathbf{X}} - \mu_0)'S^{-1}(\bar{\mathbf{X}} - \mu_0) \quad (26)$$

are, in ipoteza  $H$ , o repartiție **Hoteling cu  $N - 1$  grade de libertate**. Deci domeniul critic de nivel  $\alpha$  pentru verificarea ipotezei  $H$  este

$$T^2 \geq T_{N-1,\alpha}^2, \text{ unde } P(T_{N-1}^2 \geq T_{N-1,\alpha}^2) = \alpha.$$

Puterea testului se calculează cu ajutorul repartiției  $T^2$  necentrate cu parametrul de excentricitate

$$\delta^2 = N(\mu - \mu_0)'\Sigma^{-1}(\mu - \mu_0) \quad (26')$$

adică

$$\pi(\mu) = P(T_{N-1;\delta}^2 \geq T_{N-1,\alpha}^2). \quad (26'')$$

**$T_2$ . Problema celor două selecții când matricile de covarianță sunt necunoscute și egale.** Fie  $\mathbf{X}^{(1)} \rightsquigarrow N(\mu_1, \Sigma)$ ,  $\mathbf{X}^{(2)} \rightsquigarrow N(\mu_2, \Sigma)$  și două selecții de volume  $N_1, N_2$  respectiv. Se cere testarea ipotezei  $H : \mu_1 = \mu_2$  cu alternativa  $\mathcal{N}H : \mu_1 \neq \mu_2$ .

Matricea de covarianță comună se estimează cu

$$S = \frac{1}{N_1 + N_2 - 2} \left\{ \sum_{i=1}^{N_1} (\mathbf{X}_i^{(1)} - \overline{\mathbf{X}}^{(1)})(\mathbf{X}_i^{(1)} - \overline{\mathbf{X}}^{(1)})' + \sum_{j=1}^{N_2} (\mathbf{X}_j^{(2)} - \overline{\mathbf{X}}^{(2)})(\mathbf{X}_j^{(2)} - \overline{\mathbf{X}}^{(2)})' \right\}. \quad (27)$$

Deoarece  $\overline{\mathbf{X}}^{(1)} - \overline{\mathbf{X}}^{(2)} \rightsquigarrow N(\mathbf{0}, \frac{N_1 + N_2}{N_1 N_2} \Sigma)$ , rezultă că statistica

$$T^2 = \frac{N_1 N_2}{N_1 + N_2} (\overline{\mathbf{X}}^{(1)} - \overline{\mathbf{X}}^{(2)})' S^{-1} (\overline{\mathbf{X}}^{(1)} - \overline{\mathbf{X}}^{(2)}), \quad (28)$$

are repartiția  $T_{N_1 + N_2 - 2}^2$ . Atunci, domeniul critic al testului este

$$T^2 \geq T_{N_1 + N_2 - 2, \alpha}, \text{ unde } T_{N_1 + N_2 - 2, \alpha}^2 = \frac{(N_1 + N_2 - 2)k}{N_1 + N_2 - k - 1} F_{k, N_1 + N_2 - k - 1, \alpha}, \quad (28')$$

iar puterea testului se calculează cu  $T^2$  necentrat cu parametrul de excentricitate

$$\delta^2 = \frac{N_1 N_2}{N_1 + N_2} (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2). \quad (28'')$$

**$T_3$ . Problema celor două selecții când matricile de covarianță sunt necunoscute și diferite.** Presupunem deci că se dau vectorii normali  $\mathbf{X}^{(1)} \rightsquigarrow N(\mu_1, \Sigma_1)$ ,  $\mathbf{X}^{(2)} \rightsquigarrow N(\mu_2, \Sigma_2)$ ,

selecțiile corespunzătoare de volume  $N_1, N_2$  și se cere să se testeze ipoteza  $H : \mu_1 = \mu_2$  cu alternativa  $\mathcal{N}H : \mu_1 \neq \mu_2$ .

Dacă până acum construcția testelor  $T^2$  decurgea asemănător testelor  $t$  din statistica unidimensională aici construcția presupune **un atificial** ce va fi prezentat în continuare. Astfel să presupunem că  $N_1 < N_2$ . (În caz contrar schimbăm notarea vectorilor normali!). Din selecțiile  $\mathbf{X}_i^{(1)}, 1 \leq i \leq N_1$  și  $\mathbf{X}_j^{(2)}, 1 \leq j \leq N_2$ , construim o **nouă selecție**  $\mathbf{Y}_i, 1 \leq i \leq N_1$  astfel

$$\mathbf{Y}_i = \mathbf{X}_i^{(1)} - \sqrt{\frac{N_1}{N_2}} + \frac{1}{N_1 N_2} \sum_{s=1}^{N_1} \mathbf{X}_s^{(1)} - \frac{1}{N_2} \sum_{j=1}^{N_1} \mathbf{X}_j^{(2)}, 1 \leq i \leq N_1. \quad (29)$$

Se arată că valorile de selecție  $\mathbf{Y}_i, 1 \leq i \leq N_1$  sunt independente stochastice și repartizate normal

$$N(\mu_1 - \mu_2, \Sigma), \text{ unde } \Sigma = \Sigma_1 + \frac{N_1}{N_2} \Sigma_2. \quad (30)$$

Matricea  $\Sigma$  se estimează cu

$$S = \frac{1}{N_1 - 1} \sum_{j=1}^{N_1} (\mathbf{Y}_j - \bar{\mathbf{Y}})(\mathbf{Y}_j - \bar{\mathbf{Y}})' \quad (30')$$

iar în ipoteza  $H$  statistica

$$T^2 = N_1 \bar{\mathbf{Y}}' S^{-1} \bar{\mathbf{Y}} \quad (31)$$

are  $N_1 - 1$  grade de libertate. Domeniul critic al testului este în acest caz

$$T^2 \geq T_{N_1-1, \alpha}^2, \quad (31')$$

iar puterea testului este

$$\pi(\mu_1 - \mu_2) = P(T_{N_1-1; \delta}^2 \geq T_{N_1-1, \alpha}^2); \delta^2 = N_1 (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2). \quad (31'')$$

$T_4$ . **Problema celor  $r$  selecții când matricile de covarianță sunt necunoscute și egale.** Problema se tratează în paralel cu cazul  $\mathbf{H}_4$ . Fie  $\mathbf{X}_\alpha^{(i)}, 1 \leq i \leq r, 1 \leq \alpha \leq N_i$  cele  $r$  selecții, selecția  $\mathbf{X}_\alpha^{(i)}$  fiind efectuată asupra populației normale  $N(\mu_i, \Sigma)$ . Se cere testarea ipotezei  $H : \mu = \sum_{i=1}^r \beta_i \mu_i = \mu_0$ , cu alternativa  $\mathcal{N}H : \mu \neq \mu_0$ . Matricea  $\Sigma$  se estimează în mod obișnuit adică

$$S = \frac{1}{\sum_{i=1}^r N_i - r} \sum_{i=1}^r \sum_{\alpha=1}^{n_i} (\mathbf{X}_\alpha^{(i)} - \overline{\mathbf{X}}^{(i)}) (\mathbf{X}_\alpha^{(i)} - \overline{\mathbf{X}}^{(i)})', \quad (32)$$

și deoarece  $\sum_{i=1}^r \beta_i \overline{\mathbf{X}}^{(i)} - \mu_0 \rightsquigarrow N(\mathbf{0}, \Sigma_*)$  unde

$$\Sigma_* = \left( \sum_{i=1}^r \frac{\beta_i^2}{N_i} \right) \Sigma,$$

rezultă statistica test

$$T^2 = \left( \sum_{i=1}^r \frac{\beta_i^2}{N_i} \right) \left( \sum_{i=1}^r \beta_i \overline{\mathbf{X}}^{(i)} - \mu_0 \right)' S^{-1} \left( \sum_{i=1}^r \beta_i \overline{\mathbf{X}}^{(i)} - \mu_0 \right) \quad (32')$$

care are  $f = \sum_{i=1}^r N_i - k$  grade de libertate. Domeniul critic este deci

$$T^2 \geq T_{f,\alpha}^2, \quad T^2 \text{ dat de (32')}, \quad (33)$$

iar puterea testului se calculează cu  $T^2$  necentrat adică

$$\pi(\mu) = P(T_{f;\delta} \geq T_{f,\alpha}^2), \quad (33')$$

cu

$$\delta^2 = \left( \sum_{i=1}^r \frac{\beta_i^2}{N_i} \right)^{-1} \left( \sum_{i=1}^r \beta_i \overline{\mu}_i - \mu_0 \right)' \Sigma^{-1} \sum_{i=1}^r \beta_i \mu_i - \mu_0. \quad (33'')$$

**$T_5$ . Problema celor  $r$  selecții, cazul general.**

Presupunem că se dau  $r$  selecții  $\mathbf{X}_\alpha^{(i)}, 1 \leq i \leq r, 1 \leq \alpha \leq N_i$  din populațiile normale independente  $N(\mu_i, \Sigma_i), 1 \leq i \leq r$ , cu  $\Sigma_i$  necunoscute și ne egale. Se cere să se verifice ipoteza  $H : \mu = \sum_{i=1}^r \beta_i \mu_i = \mu_0$  cu alternativa  $\mathcal{N}H : \mu \neq \mu_0$ , unde  $\mu_0$  și coeficienții  $\beta_i, 1 \leq i \leq r$  sunt dați.

Și aici se aplică un artificiu asemănător celui din cazul  $T_3$ . Presupunem că  $N_1 = \min_{1 \leq i \leq r} N_i$ . (In caz contrar schimbăm numerotarea astfel încât  $N_1$  să fie cel mai mic). Construim selecția

$$\mathbf{Y}_\alpha = \beta_1 \mathbf{X}_\alpha^{(1)} + \sum_{i=1}^r \sqrt{\frac{N_1}{N_i}} \left( \mathbf{X}_\alpha^{(i)} - \frac{1}{N_i} \sum_{\nu=1}^{N_i} \mathbf{X}_\nu^{(i)} + \frac{1}{\sqrt{N_1 N_i}} \sum_{\gamma=1}^{N_i} \mathbf{X}_\gamma^{(i)} \right). \quad (34)$$

Se arată că variabilele de selecție  $\mathbf{Y}_\alpha$  sunt independente stochastice și repartizate normal

$$N(\mu, \Sigma_*), \Sigma_* = \sum_{i=1}^r \frac{\beta_i^2 N_1}{N_i} \Sigma_i. \quad (35)$$

Fie estimăția lui  $\Sigma_*$

$$S = \frac{1}{N_1 - 1} \sum_{i=1}^{N_1} (\mathbf{Y}_\alpha - \bar{\mathbf{Y}})(\mathbf{Y}_\alpha - \bar{\mathbf{Y}})'. \quad (35')$$

Dacă notăm cu  $S_i$  estimatia lui  $\Sigma_i, 1 \leq i \leq r$  se arată că

$$S = \sum_{i=1}^r \frac{\beta_i^2 N_1}{N_i} S_i. \quad (35'')$$

Statistica test pentru ipoteza  $H$  este

$$T^2 = N_1 (\bar{\mathbf{Y}} - \mu_0)' S^{-1} (\bar{\mathbf{Y}} - \mu_0) \quad (36)$$



și ea are (in ipoteza  $H$ ) repartiția Hoteling cu  $N_1 - 1$  grade de libertate. De aici rezultă că domeniul critic al testului este

$$T^2 \geq T_{N_1-1,\alpha}, \quad (36)$$

iar puterea testului este

$$\pi(\mu) = P(T_{N_1-1;\delta}^2 \geq T_{N_1-1,\alpha}), \quad \delta^2 = N_1(\mu - \mu_0)' \Sigma_*^{-1}(\mu - \mu_0). \quad (36')$$

**$T_6$ . Problema simetriei când  $\Sigma$  este necunoscut.** Se dă deci selecția  $\mathbf{X}_\alpha, 1 \leq \alpha \leq N$  asupra unei populații normale  $N(\mu, \Sigma), \mu = (\mu_1, \dots, \mu_k)'$  cu  $\Sigma$  necunoscut. Se cere să se testeze ipoteza  $H : \mu_1 = \dots = \mu_k$  cu alternativa  $\mathcal{N}H$  care înseamnă că nu toate  $\mu_i$  sunt egale. Ca și în cazul  $H_5$ , se alege matricea  $C^{k \times (k-1)}$  astfel încât

$$C\epsilon = 0, \quad \epsilon = (1, 1, \dots, 1)'$$

iar ipoteza  $H$  este echivalentă cu  $C\mu = 0$ . Dacă considerăm estimația obișnuită  $S$  a lui  $\Sigma$ , și estimația  $\bar{\mathbf{X}}$  a lui  $\mu$ , atunci rezultă că  $C\bar{\mathbf{X}} \rightsquigarrow N(C\mu, C\Sigma C')$  și deci statistica

$$T^2 = N(C\bar{\mathbf{X}})'(C\Sigma C')^{-1}(C\bar{\mathbf{X}}) \quad (37)$$

are repartiția Hoteling cu  $N - 1$  grade de libertate ( pe spațiul  $k - 1$  dimensional!). Domeniul critic al testului este

$$T^2 \geq T_{N-1,\alpha}^2, \quad T_{N-1,\alpha}^2 = \frac{(N-1)(k-1)}{(N-k)(k-1)} F_{k-1, N-k, \alpha}. \quad (37')$$

Puterea testului se calculează cu variabila Hoteling necentrată (pe spațiul  $k - 1$  dimensional) și anume

$$\pi(\mu) = P(T_{N-1;\delta}^2 \geq T_{N-1,\alpha}^2), \quad \delta^2 = N(C\mu)'(C\Sigma C')^{-1}(C\mu). \quad (37'')$$

## Considerații finale.

1. Aici s-au prezentat numai considerații introductive privind verificarea ipotezelor statistice. Probleme ca: **verificarea ipotezelor folosind selecțiile cenzurate ce intervin în fiabilitate, etc; testele secvențiale; analiza dispersională; teste bazate pe statistici de ordine; teste pentru serii dinamice cu multiple aplicații în activități bancare; etc** am considerat că-și au locul în prezentări speciale separate.

2. Pentru aplicarea testelor prezentate, se impun unele precizări legate de utilizarea tehnicilor moderne de calcul.

2.1. Toate funcțiile de repartiție pot fi calculate cu pachetele de programe statistice existente. Astfel se pot determina atât cuantilele cât și valorile acestor funcții. Este o problemă însă cu utilizarea funcțiilor de repartiție ne-centrate. Deoarece expresiile densităților de repartiție ale lui  $t$ -necentrat,  $\chi^2$ -necentrat și  $F$ -necentrat sunt date de serii de puteri, folosirea acestor expresii la calculul numeric al funcțiilor de repartiție sau al cuantilelor (când trebuie rezolvată o ecuație în  $x$  de forma  $F(x) = p$ ), este complicată. O ieșire din impas o poate reprezenta **aproximarea lui Pathnaik** pentru repartiția  $\chi^2_{k;\delta}$  și anume: se aproximează repartiția acestei variabile cu o variabilă repartiție de forma  $c\chi^2_{k^*}$ , adică

$$\chi^2_{k;\delta} = c\chi^2_{k^*}. \quad (38)$$

Egalând mediile și dispersiile celor două variabile din (38) rezultă

$$k + \delta^2 = ck^*, \quad k + 2\delta^2 = c^2k^*, \quad (38')$$

de unde

$$c = \frac{k + 2\delta^2}{k + \delta^2}, \quad k^* = \frac{(k + \delta^2)^2}{k + 2\delta^2}. \quad (38'')$$

Soluția  $k^*$  din (38'') se **rotunjește la un întreg**. Pentru utilizarea repartițiilor  $F$  și  $T^2$  necentrate se poate utiliza în prealabil aproximarea repartiției  $\chi^2$  necentrată ce intră în definiția lui  $F$  necentrată. Trebuie subliniat faptul că aproximarea Pathnaik este ne recomandată, fiind prea laxă.

**2.2. Simularea Monte Carlo** oferă o alternativă facilă și mai bună pentru determinarea puterii testului în cazul unei repartiții necentrate (sau oricărei alte repartiții) și anume:

- în ipoteza  $\mathcal{N}H$ , se simulează o selecție de volum mare  $n$ , a statisticii test  $g$ :

- cu această selecție se determină estimarea puterii testului

$$\pi_n = 1 - F_n(x_\alpha) \approx P(g > x_\alpha),$$

unde  $x_\alpha$  este valoarea critică a statisticii test.

**Dacă nu se poate utiliza ușor sau nu se cunoaște** expresia convenabilă a repartiției statisticii test  $g$ , atunci se procedează în mod asemănător, adică:

- se simulează o selecție de volum mare  $n$ , a statisticii test  $g$  în ipoteza  $H$ ;

- Se construiește histograma lui  $g$  pe baza acestei selecții;

- cu ajutorul histogramei se rezolvă ecuația

$$P(g > x_\alpha) = \alpha,$$

unde  $\alpha$  este riscul de genul întâi,  $x_\alpha$  fiind valoarea critică a statisticii test. (Problema inversă celei precedente).

Când selecțiile de care dispunem au un volum mic, se poate folosi **metoda bootstrap** de re-selecție, care produce multe replici ale selecției inițiale, ce pot permite o abordare **asimptotică** a analizei statistice a datelor originale ale selecției.

**3. Verificarea ipotezei de normalitate unidimensională,** nu ridică nicio problemă. Nu s-a menționat ceva semnificativ privind **verificarea ipotezei de normalitate multidimensională.** In acest sens, recomandăm lucrările [3,4] de la bibliografie care prezintă **adaptarea** testului de concordanță  $\chi^2$  in acest caz.

**3.1. Cazul specificat.** S-a văzut că testul  $\chi^2$  presupune ca spațiul  $R^p = \Delta$ , care reprezintă mulțimea valorilor vectorului  $p$ -dimensional  $\mathbf{X} \rightsquigarrow N(\mu, \Sigma)$ , sa fie divizat in  $k$  părți disjuncte, fără **a se impune** cum se alege diviziunea. In lucrările menționate se pleacă de la ideea că forma pătratică

$$\Phi(\mathbf{x}) = (\mathbf{x} - \mu)' \Sigma^{-1} (\mathbf{x} - \mu)$$

permite divizarea spațiului  $R^p$  in **coroane de elipsoizi**, determinate de  $k - 1$  constante  $0 < \theta_0 < \dots < \theta_{k-1}$ . Astfel spațiul  $R^p$  se divide in  $k$  mulțimi disjuncte de forma

$$\Delta_1 = \{\mathbf{x} | 0 \leq \Phi(\mathbf{x}) \leq \theta_1\}, \Delta_i = \{\mathbf{x} | \theta_{i-1} < \Phi(\mathbf{x}) \leq \theta_i, 2 \leq i \leq k-1\},$$

$$\Delta_k = \{\mathbf{x} | \Phi(\mathbf{x}) > \theta_{k-1}\}. \quad (39)$$

Deoarece

$$(\mathbf{X} - \mu)' \Sigma^{-1} (\mathbf{X} - \mu) = \chi_p^2, \quad (40)$$

adica are o repartiție  $\chi_p^2$ , rezultă că

$$\begin{aligned} p_1 &= P(\mathbf{X} \in \Delta_1) = P(\chi_p^2 \leq \theta_1), p_i = P(\mathbf{X} \in \Delta_i) = \\ &= P(\theta_{i-1} < \chi_p^2 \leq \theta_i), 2 \leq i \leq k-1, p_k = P(\mathbf{X} \in \Delta_k) = P(\chi_p^2 > \theta_{k-1}). \end{aligned} \quad (40')$$

Frecvențele  $f_i$  care intervin in testul de concordanță  $\chi^2$  se calculează simplu, numărând valorile de selecție ce cad in  $\Delta_i, 1 \leq i \leq k$ .

**3.2. Cazul nespecificat.** In acest caz, construcția statisticii testului de concordanță  $\chi^2$  se realizează în următorii pași (pentru selecția  $\mathbf{X}_1, \dots, \mathbf{X}_n$  de volum  $n$  mare):

- se separă o (sub)selecție de volum  $n_1 < n$ ;
- cu această selecție se estimează parametri  $\mu$  și  $\Sigma$  cu formulele obișnuite (adica  $\mu \approx \bar{\mathbf{X}}, \Sigma \approx S$ ); se observă că variabilele

$$(\mathbf{X}_i - \bar{\mathbf{X}})' S^{-1} (\mathbf{X}_i - \bar{\mathbf{X}}), n_1 < i \leq n$$

sunt repartizate  $T_{n_1-1}^2$  pe spațiul  $R^p$ .

- construcția continuă ca în cazul specificat, elipsoizii fiind de același tip, dar probabilitățile teoretice  $p_i$  se calculează cu repartiția  $T_{n_1-1}^2$  pe  $R^p$  în loc de  $\chi_p^2$ .

## References

- [1] Gheorghe MIHOC, Virgil CRAIU.(1977).**Tratat de statistică matematică, Vol.II. Verificarea ipotezelor statistice, Editura Academiei.**
- [2] Ion VADUVA. (1970). **Analiză dispersională. Editura Tehnică.**
- [3] Ion VĂDUVA and Nicolae POPOVICIU.(1979).” $\chi^2$  test of goodness of fit for multivariate normal distribution. Specified case”. *Econ.Comp.Econ.Cyb.St. and Res.,No. 2, 1979,p.93-109.*
- [4] Ion VĂDUVA and Nicolae POPOVICIU.(1980).” $\chi^2$  test of goodness of fit for multivariate normal distribution.Unspecified case”. *Econ.Comp.Econ.Cyb.St. and res., No 1, 1980,p.33-42.*