

⑥ 林の Normality Test に就て

阪大理学部数学教室 小川 潤次郎

Sample Size N が充分大きい場合に用い得る Normality Test として林知己夫氏お次のような Test を提唱している。(1)
即ち大小 N の標本 X_1, X_2, \dots, X_N の順序が Randomize されているとき, これを 2 群に分つて

第一群 : $X_1, X_2, \dots, X_{2n+1}$

第二群 : X_{2n+2}, \dots, X_N

として, 第二群は改めて

Y_1, Y_2, \dots, Y_{f+1}

とかく。従つて

$$(2n+1) + (f+1) = N$$

f を小さく, n を充分大と考える。

第一群の Median を \tilde{X} とし, 第二群から統計量

$$S^2 = \frac{1}{f} \sum_{i=1}^{f+1} (Y_i - \bar{Y})^2, \quad \bar{Y} = \frac{1}{f+1} \sum_{i=1}^{f+1} Y_i$$

を求める。 n が充分大ならば, 母集団が $N(x; 0; \sigma^2)$ のとき \tilde{X} の分布は漸近的に $N(\tilde{x}; 0, \sigma^2 \frac{\pi}{4n+2})$ で, S^2 の分布は exact に自由度 f の χ^2 分布

$$p(s)ds = \frac{f^{\frac{f}{2}}}{2^{\frac{f-2}{2}} \Gamma(\frac{f}{2}) \sigma^f} s^{f-1} e^{-\frac{fs^2}{2\sigma^2}} ds$$

で、且つ \tilde{X} と S と互に独立であることを用いて

$$T = \sqrt{\frac{4n+2}{\pi}} \cdot \frac{\tilde{X}}{S}$$

とおくと、 T の漸近分布は

$$p(t)dt = \frac{1}{\sqrt{\pi f}} \frac{\Gamma(\frac{f+1}{2})}{\Gamma(\frac{f}{2})} \left(1 + \frac{t^2}{f}\right)^{-\frac{f+1}{2}}$$

即ち、自由度 f の Student の t 分布となることを利用して、
例えば $f = 10$, $n = 100$ ならば

$$t_{0.05} = 2.228$$

だから

$$\left| \frac{\tilde{X}}{S} \right| \geq 2.228 \sqrt{\frac{\pi}{4n+2}} \doteq 0.0174$$

のとき Normality の仮説を棄却しようとするのが林氏の Test である。

しかし、このとき対立仮説として

$$N(x; \mu, \sigma^2) \quad \mu \neq 0$$

を取り得ることを考えれば、統計量 T の値が

$$|T| \geq t_{\alpha} \quad (t: \text{わ } \alpha \% \text{ 点})$$

となつたからと云つて、Normality の仮説を棄却しないで $\mu = 0$ という仮説を棄却すると考えることも出来る筈で、むしろ、この方が自然

であると私は考える。 Normality Test である為ゆえに、考える統計量 T の標本分布は、パラメーター μ, σ には無関係で Functional Form のみに depend することが必要である。

この意味で Geary の b_1, b_2 を用いる Test は

$$m_v = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{X})^v, \quad \bar{X} = \frac{1}{N} \sum x_i$$

$$b_1 = \frac{m_3}{m_2^{3/2}}, \quad b_2 = \frac{m_4}{m_2^2}$$

の分布は、母集団を $N(x; \mu, \sigma^2)$ とするとき、 μ, σ^2 には無関係であるから合理的と云えるであろう。

尤も、 T の分布は exact にはパラメーター μ, σ^2 に depend しても、practically には independent と考えられるならばよい。林の Test の場合は、母集団を $N(x; \mu, \sigma^2)$ とすると、 \bar{X} と S の同時分布の Prob. element は

$$\begin{aligned} & \frac{\sqrt{2n+1} f^{\frac{f}{2}}}{2^{\frac{f-2}{2}} \pi \Gamma(\frac{f}{2}) \sigma^{f+1}} s^{f-1} e^{-\frac{2n+1}{\pi \sigma^2} (\bar{x} - \mu)^2 - \frac{f s^2}{2 \sigma}} d\bar{x} ds \\ &= \frac{\sqrt{2n+1} f^{\frac{f}{2}}}{2^{\frac{f-2}{2}} \pi \Gamma(\frac{f}{2}) \sigma^{f+1}} e^{-\frac{2n+1}{\pi \sigma^2} \mu^2} \\ & \times \sum_{r=0}^{\infty} \frac{1}{r!} \left(\frac{4n+2}{\pi \sigma^2} \mu \right)^r \bar{x}^r s^{f-1} e^{-\frac{s^2}{2 \sigma^2} \left(\frac{4n+2}{\pi} \frac{\bar{x}^2}{s^2} + f \right)} d\bar{x} ds \end{aligned}$$

$$\sqrt{\frac{4n+2}{\pi}} \frac{\bar{x}}{s} = t$$

とおくと、

$$p(t, s) dt ds = \frac{\sqrt{2n+1} f^{\frac{f}{2}}}{2^{\frac{f-1}{2}} \pi \Gamma(\frac{f}{2}) \delta^{f+1}} e^{-\frac{2n+1}{\pi \delta^2} \mu^2} \sum_s \frac{1}{r!} \left(\frac{4n+2}{\pi}\right)^{\frac{f}{2}-1} \frac{\mu^r}{\sigma^{2r}} t^r \times \delta^{f+r} e^{-\frac{\delta^2}{2\sigma^2}(t^2+f)} ds dt.$$

$$\delta^2 \equiv \frac{4n+2}{\pi \sigma^2} \mu^2$$

とあいて、 s を integrate out すると

$$p(t) dt = \frac{\left(\frac{f}{2}\right)^{\frac{f}{2}} e^{-\frac{\delta^2}{2}}}{\sqrt{2\pi} \Gamma\left(\frac{f}{2}\right)} \sum_{r=0}^{\infty} \frac{\Gamma\left(\frac{f+r}{2}\right)}{r!} (\delta t)^r \left(\frac{2}{f+t^2}\right)^{\frac{1}{2}(f+r)} dt. \quad (2)$$

これは所謂 Non-central な t 分布である。 $\delta=0$ なら $r=0$ の Term 丈のこつて

$$p_0(t) dt = \frac{\left(\frac{f}{2}\right)^{\frac{f}{2}} \Gamma\left(\frac{f+1}{2}\right)}{\sqrt{2\pi} \Gamma\left(\frac{f}{2}\right)} \left(\frac{2}{f+t^2}\right)^{\frac{1}{2}(f+1)} dt$$

となつて自由度 f の t 分布になる。 これを Non-central な t 分布の性質からして practically に independent という訳は行かない。

多分林氏計算の簡便という点を無視して第一群の Median をとつたのであろうが、次のような Test を作れば、Geary より計算が簡便で、一応の条件が満たされる。 即ち X_1, \dots, X_{n_1} を 2 群に分つて

$$\text{第一群} \quad X_1, X_2, \dots, X_{n_1}$$

$$\text{第二群} \quad X_{n_1+1} = Y_1, X_{n_1+2} = Y_2, \dots, X_N = Y_{n_2}$$

$$n_1 + n_2 = N$$

として、これから

$$S_1^2 = \frac{1}{n_1 - 1} \sum_{x=1}^{n_1} (X_x - \bar{X}), \quad \bar{X} = \frac{1}{n_1} \sum X_x$$

$$S_2^2 = \frac{1}{n_2 - 1} \sum_{x=1}^{n_2} (Y_x - \bar{Y}), \quad \bar{Y} = \frac{1}{n_2} \sum Y_x$$

なる統計量を作ると

$$F = \frac{S_1^2}{S_2^2}$$

な、母集団を $N(\mu, \sigma^2)$ とすれば、 μ, σ^2 に無関係に $n_1 - 1$ の自由度、 $n_2 - 1$ の F 分布に従う。

Student の有名な Data⁽³⁾ についてこの Test を用いて見る。

$$X_1 = 1.9, X_2 = 0.8, X_3 = 1.1, X_4 = 0.1, X_5 = -0.1$$

$$Y_1 = 4.4, Y_2 = 5.5, Y_3 = 1.6, Y_4 = 4.6, Y_5 = 3.4$$

$$\bar{X} = 0.76 \quad \bar{Y} = 3.90$$

$$4 S_1^2 = \sum X_x^2 - 5 \times \bar{X}^2 = 2.5420$$

$$4 S_2^2 = \sum Y_x^2 - 5 \times \bar{Y}^2 = 9.4400$$

$$F = \frac{2.5420}{9.4400} \doteq 0.27$$

$F_4^4(0.01) = 15.98, F_4^4(0.05) = 6.39$ だから
Significant でない。即ち Normality を棄却する訳はわからない。

このよるな Normality Test の Efficiency については又別の機会にのべ度い。
(1950. 4. 10)

(1) C. Hayashi : Fragments of a New Test Formula of Normality, Annals of the Institute of Statistical Math. Vol. 1. No. 2. 1950. pp. 125 - 130.

(2) 例之ば, C.C. Craig : Note on the Distribution of Non-Central t with An Application, Ann. of Math. Stat. Vol. 12. 1941.

N.L. Johnson and B.L. Welch : Applications of the non-central t -distribution. Biometrika Vol. 31. 1940. pp. 362 - 359.

(3) Student : The probable error of a mean : Biometrika. Vol. 6. 1908. p. 1.

(受付 1950 9.14)