

ま之がき 異なる原因によって生起する事象の度数分布曲線は、複数個のピークを持つ可能性がある。たとえば降雨量はその発生原因である台風、前線、季節風などによって明瞭に差が生じ度数分布曲線にピークが幾つが生ずることがある。このように、水文量の度数分布はときたま二つ以上のピークを持つが、目下その統計的処理方法が見当らない。本報では、二つのピークを有する場合の標本値の統計的処理方法を、正規分布する場合と対称正規分布する場合とについて考える。それには、与えられた大きさ n の標本（これを標本 n とする）を原因別に二つの標本 n_1 と n_2 に篩い分けることができればよい。超過確率を求める場合には、標本 n を原因別に二つの標本 n_1 と n_2 に分け、これらより超過確率を求め加重平均すれば、篩い分けずに求めた超過確率より正確である。

1.1 二つの正規分布の混合

二つのピークを持つ大きさ n の標本

$$\{x_i\} = \{x_1, x_2, x_3, \dots, x_n\} \quad (1)$$

を原因別にならぬ方法で大きさ n_1, n_2 の二つの標本

$$\{x_{i1}\} = \{x_{11}, x_{12}, x_{13}, \dots, x_{1n_1}\} \quad (2)$$

$$\{x_{ij}\} = \{x_{21}, x_{22}, x_{23}, \dots, x_{2n_2}\} \quad (3)$$

に分離できたものとする

$$n = n_1 + n_2$$

$$\{x_i\} = \{x_{i1}\} + \{x_{ij}\}$$

となり、各標本の平均値はそれぞれ次式となる。

$$\begin{aligned} \bar{x}_1 &= \frac{1}{n_1} \sum_{i=1}^{n_1} x_{i1}, \quad \bar{x}_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} x_{2j} \\ \bar{x} &= \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \left\{ \sum_{i=1}^{n_1} x_{i1} + \sum_{j=1}^{n_2} x_{2j} \right\} = \frac{1}{n} \{ n_1 \bar{x}_1 + n_2 \bar{x}_2 \} \\ \bar{x} &= \alpha_1 \bar{x}_1 + \alpha_2 \bar{x}_2 \end{aligned}$$

$$\text{ただし, } \alpha_1 = n_1/n, \alpha_2 = n_2/n \quad \therefore \alpha_1 + \alpha_2 = 1 \quad (4)$$

標準偏差はそれぞれ

$$\sigma_1 = \sqrt{\frac{1}{n_1} \sum_{i=1}^{n_1} (x_{i1} - \bar{x}_1)^2}, \quad \sigma_2 = \sqrt{\frac{1}{n_2} \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_2)^2}$$

となり、 σ はつぎのようにして求められる。

$$\bar{x}_1 < \bar{x}_2, \quad \Delta \bar{x} = \bar{x}_2 - \bar{x}_1$$

とおけば

$$\bar{x} = \bar{x}_1 + \alpha_2 \Delta \bar{x}$$

$$\bar{x} = \bar{x}_2 - \alpha_1 \Delta \bar{x}$$

したがって

$$\begin{aligned} n\sigma^2 &= \sum_{i=1}^n (x_i - \bar{x})^2 \\ &= \sum_{i=1}^{n_1} (x_{i1} - \bar{x})^2 + \sum_{j=1}^{n_2} (x_{2j} - \bar{x})^2 \\ &= \sum_{i=1}^{n_1} \{ (x_{i1} - \bar{x}_1) - \alpha_2 \Delta \bar{x} \}^2 + \sum_{j=1}^{n_2} \{ (x_{2j} - \bar{x}_2) + \alpha_1 \Delta \bar{x} \}^2 \\ &= n_1 \sigma_1^2 + n_2 \sigma_2^2 + n \alpha_1 \alpha_2 (\Delta \bar{x})^2 \end{aligned}$$

$$\therefore \sigma^2 = \alpha_1 \sigma_1^2 + \alpha_2 \sigma_2^2 + \alpha_1 \alpha_2 (\Delta \bar{x})^2 \quad (5)$$

また、確率密度関数はそれぞれ

$$\begin{aligned} f_1(x) &= \frac{1}{\sqrt{2\pi} \sigma_1} e^{-\frac{(x - \bar{x}_1)^2}{2\sigma_1^2}} \\ f_2(x) &= \frac{1}{\sqrt{2\pi} \sigma_2} e^{-\frac{(x - \bar{x}_2)^2}{2\sigma_2^2}} \end{aligned}$$

となり、 $f(x)$ はつぎのようにして求められる。

確率変数 x に対する標本 n の度数 $nf(x)$ は、標本 n_1 および n_2 の度数 $n_1 f_1(x)$ および $n_2 f_2(x)$ の和であるから

$$nf(x) = n_1 f_1(x) + n_2 f_2(x)$$

$$\therefore f(x) = \alpha_1 f_1(x) + \alpha_2 f_2(x) \quad (6)$$

となる。標本 n の超過確率 $W(x)$ は、標本 n_1 および標本 n_2 の超過確率 $W_1(x), W_2(x)$ の加重和であり、

$$W(x) = \alpha_1 W_1(x) + \alpha_2 W_2(x) \quad (7)$$

となる。 $W_1(x), W_2(x)$ は正規分布の超過確率であり正規分布の表より計算できる。

1.2 二つの正規分布の混合標本の分離法

標本 n を原因別に二つの標本 n_1 および n_2 とに分離する手順を箇条書きに示す。

- ① 度数分布曲線または確率密度曲線図-1を描き、ピークの生じる位置を近似的に $\bar{x}_1, \bar{x}_2$ として、 $\Delta \bar{x} = \bar{x}_2 - \bar{x}_1$ を求める。




図-1

- ② $\bar{x} = \sum x_i / n$ を計算し、次式により α_1, α_2 を求める。

$$\begin{cases} \bar{x} = \alpha_1 \bar{x}_1 + \alpha_2 \bar{x}_2 \\ \alpha_1 + \alpha_2 = 1 \end{cases}$$

③ $\sigma = \sqrt{\{\sum (x_i - \bar{x})^2\}/n}$ を計算する。

④ $\bar{x}_1$ および $\bar{x}_2$ の外側で、ヒューフ付近の任意の点 x の $f(x)$ を図-1より読み取り

$$\begin{cases} f(x) = \alpha_1 f_1(x) + \alpha_2 f_2(x) \\ \sigma^2 = \alpha_1 \sigma_1^2 + \alpha_2 \sigma_2^2 + \alpha_1 \alpha_2 (\Delta \bar{x})^2 \end{cases}$$

より α_1 および α_2 を求める。

⑤ ①~④で求めた $\bar{x}_1$, $\bar{x}_2$ および σ_1 , σ_2 を用い $f(x)$ を計算し、これと①の $f(x)$ と比較し、一致するまで①~⑤を繰り返す。

2.1 対数正規分布

対数正規分布は確率変数 x を $Z = \log_{10} x$ により Z に変換すれば正規分布となる分布である。

$$g(x) = \frac{\log_{10} e}{\sqrt{2\pi} \sigma_0} \cdot \frac{1}{x} \cdot e^{-\frac{1}{2\sigma_0^2} (\log_{10} \frac{x}{x_0})^2} \quad \dots \dots (8)$$

は、置換 $Z = \log_{10} x$ により

$$g(x) dx = \frac{1}{\sqrt{2\pi} \sigma_0} e^{-\frac{(Z - \bar{Z})^2}{2\sigma_0^2}} dZ = f(Z) dZ$$

となる。

$$\therefore f(Z) = \frac{1}{\sqrt{2\pi} \sigma_0} e^{-\frac{(Z - \bar{Z})^2}{2\sigma_0^2}} \quad \dots \dots (9)$$

となり、 $f(Z)$ は正規分布関数となるから、 $g(x)$ は対数正規分布関数である。

$$\text{ただし、} \bar{Z} = \log_{10} \bar{x} = \log_{10} x_0 \quad \dots \dots (10)$$

$$\sigma_0 = \sqrt{\frac{1}{n} \sum (\log_{10} x_i - \log_{10} x_0)^2} \quad \dots \dots (11)$$

で、 x_0 は分布 $g(x)$ の中央値であり、 σ_0 は正規分布 $f(Z)$ の標準偏差である。

つぎに、分布 $g(x)$ の最頻値 x_m を求めると

$$x_m = x_0 \cdot 10^{-\sigma_0^2 / \log_{10} e} \quad \dots \dots (12)$$

となり

$$g(x_m) = \frac{\log_{10} e}{\sqrt{2\pi} \sigma_0} \frac{10^{(\sigma_0^2 / \log_{10} e)}}{x_0} \cdot e^{-\frac{1}{2} (\sigma_0^2 / \log_{10} e)^2}$$

となる。

2.2 二つの対数正規分布の混合標本の分離法

分離手順を箇条書きに示す。

① 対数正規分布曲線図-2より、近似的に最頻値 x_{m1} , x_{m2} を読み取る。 x_{m2} はやや精度が悪い。

② 正規分布曲線図-3より、 Z_1 , Z_2 を読み取り、中央値 x_{01} , x_{02} を求める。 x_{01} は精度が悪い。したがって $\Delta \bar{Z}$ も精度が悪い。

③ $\bar{Z}$, σ_0 を計算する。

④ x_{m1} , x_{02} および式(12)より、 $\sigma_{02} = \sqrt{\log_{10} e \cdot \log_{10} (x_{02}/x_{m2})}$ を計算する。

⑤ x_{m1} , x_{01} より σ_{01} を求め、これを第1近似値として以下の計算を繰り返す。

⑥ σ_0 , σ_{01} , σ_{02} , $\Delta \bar{Z}$ の値と次式

$$\begin{cases} \alpha_1 + \alpha_2 = 1 \\ \sigma_0^2 = \alpha_1 \sigma_{01}^2 + \alpha_2 \sigma_{02}^2 + \alpha_1 \alpha_2 (\Delta \bar{Z})^2 \end{cases}$$

より、 α_1 , α_2 を求める。

⑦ x_{m1} 付近の点 x の $g(x)$ を読み取り、これと計算値 $g(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x)$

を比較し、一致しなければ、 σ_{01} を仮定しなおし、⑥に帰り一致するまで繰り返す。

⑧ 分布曲線 $g(x)$ を描き、①の分布曲線と比較する。一致しなければ①に帰り x_{m2} ②で x_{01} を修正し一致するまで①~⑧を繰り返す。以上のようにして、標本 n を n_1 , n_2 に分離して、確率・超確率および非超確率などを計算すれば分離しない場合より精度が高まる。ここで、 Z_m : 隣合う階級代表値 x の対数変換値の差




図-2




図-3

3. 資料の個数の少ない場合の処理法

標本の個数が極めて少ない場合には、これらを階級別に分けて度数分布表やヒストグラムを作成することは困難となる。このような場合には、標本値を x 軸上に大きさの順に並べ、各標本値 x_i を中心とする底辺 b_i の面積 h_i の柱状図を作成し、これより、確率密度曲線を描くことができる。これらの柱状図の幅 b_i , 高さ h_i は図-4より

$$\begin{aligned} b_i &= \frac{b_{i-1} + b_i}{2} \\ \therefore b_i &= 2b_i - b_{i-1} \\ \text{or } b_{i-1} &= 2b_i - b_i \\ \dots \dots (13) \\ h_i &= 1/n b_i \end{aligned}$$

となる。




図-4

計算方法は、最初 $b_i = b_{i-1}$ として最頻値付近より左右に計算を進める。かくして柱状図が描けたら、前節2.2または2.2.1により処理する。