

京都大学工学部 正員 池端周一
間組 K.K 正員 田中知巳

① はじめに

水文資料の観測、収集は元来地質であり、かつ長年月を要するが、得られるデータは豊富で、あるいは精度のよいが、治水・利水計画を問はず、実際の設計・操作問題においても直接的にその合理性・経済性を大きく左右するものであり、その必要性・重要性はいうまでもない。水問題でも、これ基本となる水文資料は降水であり、その空間的・時間的不確定構造を考慮すると、降水観測の観測・収集に関する、最適な観測網体系の確立が最重要課題であろう。本研究では、従来の研究成果をふまえながら、観測の行動目的を追循し、未知パラメータの推定精度向上にあらず、確率的性格の強、日単位以上の降水量の空間的・時間的実現値を知ることに主眼、その情報量を定式化し、予算の許す限り観測所をふやす、過去のデータ・非データが内蔵する情報蓄積を最大限利用する、観測所の確立・廃止・新設を同時に考慮したO.R手法を導入する、といった立場を重視して、情報量概念に基づく降水観測網の最適配置基準を設定せんとするものである。したがって、観測がもたらす情報量を、実現値を知る以前にかかれがちの予測実験を観測が解消していくべきと解釈し、Shannon流情報量を定義することに、その展開には事前分布を導入するベイズ論的立場をとっている。

② 情報量の一般的表現法

情報という概念は非常に広義なものとして理解されていながら、本研究では情報を解析的操作の対象としてとりえていくために、不確定度の度量を減少してくれるものを規定し、ある降水現象を知ることにより得られる情報量として、情報量=[事前の不確定度]-[事像の不確定度]で表現する。そして、不確定度の量的表現としては通常エントロピーと呼ばれている、 $H(x) = -\sum p_i \log p_i$ 、 $H(y|x) = -\sum p(y|x) \sum p(y|x) \log p(y|x)$ を用いた。したがって、 x の実現値を知ることにより得られる情報量 $I(x)$ は、 $I(x) = H(x) - \sum p(x) \log p(x)$ で、 y の実現値を知らなければ、 x の実現値を知ることにより y に関する得られる情報量 $I(y|x)$ は、 $I(y|x) = H(y) - H(y|x) = -\sum p(y) \log p(y) + \sum p(y|x) \sum p(y|x) \log p(y|x)$ で与えられる。ここで実際に情報量を算定するためには、確率変数 x 、 y の周辺分布や x の条件付周辺分布を知らなければならぬ。分布にはそれを導出するパラメータがあり、未知パラメータの推定に最尤法や積分法が多く用いられるが、本研究ではデータ・非データ情報を加味する意味から事前分布を導入するベイズ論的立場をとっている。したがって、将来観測にあたっては、過去にデータが豊富であれば、 $\pi(A_1|a_1, A_2) = \pi(A_1) + \pi(A_2) + \pi(A_3)$ で算出される事後確率分布が事前確率分布となり、そのパラメータ分布をもつ確率変数 x のばれが実現するこことを観測するだけであり、データがない場合でも何らかの形で事前確率分布をすれば、同様の考え方で確率変数 x を観測するこになる。

③ 観測所の確立・廃止推定および新設により得られる情報量

観測所配置計画にあたっては、各観測所から既設観測所を継続する、2)既設観測所を廃止し、基幹観測所あるいは周辺観測所から推定する、3)観測所を新設する、のいずれかの行動を選択し、その行動とともに伴って得られる情報量、その行動に要する費用とのバランス化が指向される。そこで以下では、1), 2), 3)の各場合に得られる情報量の一般的定義式を求め、さらに水文情報が正規分布または指数分布にしたがう場合の情報量をそれぞれ算定する。なお、以下では情報源から情報の発生までの過程はエルゴード的独立過程としている。

(1)既設観測所を継続する場合に得られる情報量 1)一般的定義式；既設観測所について、これまでの観測により得られていく情報(観測値)を $X(x_1, x_2, \dots, x_N)$ とする。情報 X を得て後、未知パラメータの事後確率分布 $\pi(\theta|X)$ は

ベイズの定理より、 $\hat{\pi}(\theta|X) = \hat{\pi}(\theta) f(x_1|\theta) \cdot f(x_2|\theta) \cdots f(x_N|\theta) / \int \hat{\pi}(\theta) f(x_i|\theta) d\theta$ で与えられる。 $\hat{\pi}(\theta|X)$ が求められる、 X および将来観測 $\tilde{X}(x_{N+1}, x_{N+2}, \dots, x_{N+n})$ が与えられての x_{N+n} の周辺密度関数 $f(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1})$ が X が与えられての $(x_{N+1}, \dots, x_{N+n})$ の結合密度関数 $f(x_{N+1}, \dots, x_{N+n}|X)$ はそれ次式で与えられる。

$$f(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1}) = \int \hat{\pi}(\theta|X) f(x_{N+n}|\theta) / \int \hat{\pi}(\theta|X) f(x_{N+n}|\theta) d\theta \cdots (1) f(x_{N+n}|\theta) = \int \hat{\pi}(\theta|X) f(x_{N+n}|\theta) d\theta$$

(2) ここに、 $f(x|\theta)$ は θ が与えられての x のしたがう確率密度である。ところで、観測結果の場合は観測にトリミーの x の値を知る二通りがあるから、事後の予確実さは0となり、したがって x_{N+n} を観測することにトリミー得られる情報量は、 $I^{(0)}(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1}) = - \int f(x_{N+1}, \dots, x_{N+n}|X) f(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1}) \log f(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1}) dx_{N+1} \cdots (3)$ で与えられ、またに将来 $\tilde{X}(x_{N+1}, \dots, x_{N+n})$ を観測することにより期待される情報量は、 $I^{(1)}(x_{N+1}, \dots, x_{N+n}|X) = \sum_{n=1}^N I(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1}) = - \int f(x_{N+1}, \dots, x_{N+n}|X) \log f(x_{N+1}, \dots, x_{N+n}|X) dx_{N+1} \cdots (4)$ で与えられる。ii) 正規情報の場合：平均値 μ が未知、分散 σ^2 が既知である正規分布に対して μ の事前確率分布を $N(\mu_0, V_0)$ で与えられ、(3)式、(4)式はそれぞれ次式で与えられる。 $I^{(0)}(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1}) = \frac{1}{2} (1 + \log 2\pi V_x) + \frac{1}{2} \log ((V_x + nV_0)/V_x) \cdots (5)$ 、 $I^{(1)}(x_{N+1}, \dots, x_{N+n}|X) = \frac{1}{2} (1 + \log 2\pi V_x) + \frac{1}{2} \log \frac{V_0 + V_x}{V_x} \cdots (6)$ ここに、 $V_0(x) = V_0^2/2(N-1)+D_2$ である。なお、 μ の事前分布が、あたかも一様分布とみなせる場合とか N が大きい場合には $V_0(x) = V_x/N$ となるので、上式はそれそれ簡単化、 $I^{(0)} = \frac{1}{2} (1 + \log 2\pi V_x) + \frac{1}{2} \log \frac{N+n}{N+n-1} \cdots (7)$ 、 $I^{(1)} = \frac{1}{2} (1 + \log 2\pi V_x) + \frac{1}{2} \log \frac{N+n}{N} \cdots (8)$ となる。以上は分散 σ^2 が既知とした場合の展開式であったが、実際に観測数の増加とともに平均値だけではなく、 V_x の精度も向上するのであるから、厳密には μ 、 V_x 两者を未知として解析する必要がある。この場合に事後確率分布 $\hat{\pi}(\theta|y_n|X)$ は正規ガウス分布、 $\hat{\pi}(\theta|X)$ は一般化エラストティック分布で与えられ、これらをまとめて使ったのでは以後の計算が非常に煩雑になってしまいそう。しかし率 α に N が大きい場合には $S_{x,n}^2/(N-1)/N + D_2$ の既定値として x_{N+1}, \dots, x_N が既知の分散 $V_x = S_{x,n}^2$ として正規分布をしていくのみなすことができる。また、いくつかのデータ例について厳密解を求めた結果では、 $V_x = S_{x,n}^2$ 既知とした場合に大きく異ならないので、一般的にも(7)、(8)式の V_x を $S_{x,n}^2$ と置きかえれば十分である。iii) 相情報の場合：この場合には日降水量を考へてるので、一般的過去の観測数 N が大きくなれば、1年であっても季節ごとに分割すれば $N=90$ の観測データがあることにする。事後確率分布 $\hat{\pi}(\theta|X)$ は、 $\hat{\pi}(\theta|X) = \frac{A_{N+1}}{N! \theta^{N+1} A^0}$ で十分近似できる。ここで、 $A = \sum_{i=1}^N x_i$ である。正規情報の場合と同様に展開すれば、 $I^{(0)}(x_{N+n}|X, x_{N+1}, \dots, x_{N+n-1}) = 1 + \log \frac{x_1 + x_2 + \dots + x_N}{N} + \log \frac{N+n}{N+n-1} \cdots (9)$ 、 $I^{(1)}(x_{N+1}, x_{N+2}, \dots, x_{N+n}|X) = n(1 + \log \frac{x_1 + x_2 + \dots + x_N}{N}) + \log \frac{N+n}{N} \cdots (10)$ を得られ、正規情報とよく似た式となる。

(2) 既設観測所を廃止し、基幹観測所から推定することにより得られる情報量 i) 一般的定義式；推定観測所に行われるこれまでの観測値を (y_1, \dots, y_M) 、それに対応する基幹観測所の観測値を (x_1, x_2, \dots, x_M) とすれば（一般に $M \leq N$ ）、 β_1, β_2 を回帰係数とし、 y を複合項とする複合回帰モデルは、 $y_i = \beta_1 + \beta_2 x_i + \epsilon_i$ 。ここで与えられ、 X, Y が観測された後の $\hat{\pi}(\beta_1, \beta_2|X, Y)$ は、 $\hat{\pi}(\beta_1, \beta_2|X, Y) = \hat{\pi}(\beta_1, \beta_2) f(y_1|\beta_1, \beta_2, x_1) \cdots f(y_M|\beta_1, \beta_2, x_M) / \int \hat{\pi}(\beta_1, \beta_2) f(y_1|\beta_1, \beta_2, x_1) \cdots f(y_M|\beta_1, \beta_2, x_M) d\beta_1 d\beta_2$ で与えられる。 $\hat{\pi}(\beta_1, \beta_2|X, Y)$ が求められると、 X, Y および x_{M+n} が与えられての y_{M+n} の周辺密度関数 $f(y_{M+n}|X, Y, x_{M+n})$ は、 $f(y_{M+n}|X, Y, x_{M+n}) = \int \hat{\pi}(\beta_1, \beta_2|X, Y) f(y_{M+n}|\beta_1, \beta_2, x_{M+n}) d\beta_1 d\beta_2$ で表され、その後の y_{M+n} の事後の予確実さを求めるので、[2]の議論から観測所を廃止し推定した場合に得られる情報量 $I^{(0)}(y_{M+n}|X, Y, x_{M+n})$ および既情報量 $I^{(1)}(y_{M+n}|X, Y, x_{M+n}, x_{M+n-1})$ は、それぞれ次式で与えられる。 $I^{(0)}(y_{M+n}|X, Y, x_{M+n}) = - \int f(y_{M+n}|Y) \log f(y_{M+n}|Y) dy_{M+n} + \int f(y_{M+n}|X) f(y_{M+n}|X, Y, x_{M+n}) \log f(y_{M+n}|X, Y, x_{M+n}) dy_{M+n} \cdots (11)$ 、 $I^{(1)}(y_{M+n}|X, Y, x_{M+n}, x_{M+n-1}) = \sum_{n=1}^N \int f(y_{M+n}|Y) dy_{M+n} \cdots (12)$ ここに $f(y_{M+n}|Y) = \int f(y_{M+n}|Y) f(y_{M+n}|B_y) dy_y$ である。

ii) 正規情報の場合； X, Y が観測されての β_1, β_2 の事後確率分布 $\hat{\pi}(\beta_1, \beta_2|X, Y)$ は事前確率分布 $\pi(\beta_1, \beta_2)$ が正規分布で、その平均が $m = (\mu_1, \mu_2)$ 、分散共分散行列が $V = [V_{ij}]$ 、 $i, j = 1, 2$ である場合、やはり正規分布となり、 x_{M+n} が与えられての y_{M+n} の周辺密度関数は $f(y_{M+n}|X, Y, x_{M+n}) = \frac{1}{\sqrt{2\pi V_{xy}}} e^{-\frac{1}{2V_{xy}}(y_{M+n}-\mu_1-\beta_2 x_{M+n})^2}$ 、ここで $V_{xy} = \mu_1' + 2\mu_2' x_{M+n} + V_{22}' x_{M+n}^2 + V_{xx}$ であり、 $[V_{11}' \ V_{12}'] = [\mu_1 + V_{11}\mu_2 \ \mu_2 + \sum_{i=1}^N x_i \mu_2]$ 、 $V_{12}' = \|h_{12}\|$ 、 $V_{xx} =$ 複合項の分散である。 β_1, β_2 を、この場合の情報量は(iii)式より、 $I^{(0)}(y_{M+n}|X, Y, x_{M+n}) = \frac{1}{2} \left\{ \log 2\pi V_{xy} - \log 2\pi (V_{11} + V_{22} - \frac{V_{12}^2}{V_{22}}) + \frac{1}{2} \log \frac{V_{11} + V_{22} - V_{12}^2/V_{22}}{V_{11} + V_{22} - V_{12}^2/V_{22}} - \frac{1}{2} \left(\frac{1}{V_{22}} - \frac{1}{V_{11} + V_{22} - V_{12}^2/V_{22}} \right)^{-1} \frac{1.3}{2.8} + \frac{1.3 \cdot 5}{3.8 \cdot 6 \cdot (2.5)^4} \cdots (13) \right\}$ で与えられる。方程式の説明に用いては $\log((x_{M+n} - \frac{V_{12}}{V_{22}})^2 + (V_{11}' x_{M+n} + V_{22}' - V_{12}'^2/V_{22}^2)^2)$ をマクローリン展開してある。ここで、 $\beta^2 = (V_{11}' x_{M+n} + V_{22}' - V_{12}'^2/V_{22}^2)^2/V_{22}^2$ 、 $2\delta = (V_{11}' x_{M+n} + V_{22}')/(V_{11} + V_{22})$ である。

ところで、上式は事前分布 $\xi(\theta_X)$, $\xi(\theta_Y)$ の分散要素, $\xi(\beta_1, \beta_2)$ 。分散一枚分散行列要素がより過去の雨観測所データ構造要素をすべて含んでおり、要素間の大小関係により推定情報量が変化する。しかし、各要素が同じよう情報量増減に寄与するわけではなく、事前分布の分散が大きくなると情報量は大きくなる。いま、 $\xi(\theta_Y)$, $\xi(\beta_1, \beta_2)$ の変動が観測データの個数に対して十分小さく、あたかも一様分布であるかのうに計算を進めることが許される場合を考えると、上式はより簡単になり、さらにはM, nが大きいと近似的に, $I_E^{(2)} = \frac{1}{2} (\log 2\pi V_Y - 2\pi V_E) \dots (14)$ 総情報量も $\frac{1}{2} (\log 2\pi V_Y - \log 2\pi V_E)$ で近似される。厳密には、(13)式を計算するわけであるが、(14)式と比較すると、他の項はかなり小さくなり、実用的には(14)式で十分近似である。 n 指数情報の場合；この場合は、 y_{Hm+n} の条件付周辺密度関数が、0次の変形ベセル関数を含るので、情報量算定は解析的にも数値計算的にも困難である。そこで本研究では少しだけでも数値計算が可能なよう、この場合に限り伝統的立場に立った、情報量算定期式を導いておく。 $I_E^{(2)}(y_{Hm+n}|X, Y, X_{Hm+n}) = 1 + \log \frac{d_{Hm+n}^2}{M} + \int_0^\infty \int_0^\infty e^{-\frac{\theta_2 x_{Hm+n}}{\theta_1}} e^{-\frac{1}{\theta_1}(y_{Hm+n} + \theta_2 x_{Hm+n})} \times I_0\left(2\sqrt{\frac{\theta_1}{\theta_2} x_{Hm+n}}\right) \times \log\left(\frac{1}{\theta_1} e^{-\frac{1}{\theta_1}(y_{Hm+n} + \theta_2 x_{Hm+n})}\right) I_0\left(2\sqrt{\frac{\theta_1}{\theta_2} x_{Hm+n}}\right) d x_{Hm+n} dy_{Hm+n}, T I_E^{(2)}(y_{Hm+n}|X, Y, X_{Hm+n}, X_{Hm}) = n I_E^{(2)}(y_{Hm+n}|X, Y, X_{Hm+n}) = n, \hat{\theta}_1 = M/\sum x_i, \hat{\theta}_2 = M/\sum y_i, \hat{\beta}_1 = \sum y_i/\sum x_i, \hat{\beta}_2 = \hat{\rho} \cdot \sum y_i / \sum x_i, \hat{\rho} = M/\sum x_i y_i / (\sum x_i \sum y_i - 1)$ しただし積率解である。

3) 観測所新設：より得られる情報量 新設の場合には、観測資料がないために将来の観測情報に対する事前確率分布はデータ・非データ情報から判断される $\xi(\theta)$ のものとなり、総情報量の展開式から明らかにわかるように、正規情報に関する新設情報量および総情報量は、 $I_E^{(2)}(x_n) = \frac{1}{2} (1 + \log 2\pi V) + \frac{1}{2} \log \frac{V + n V_0}{V + (n+1)V_0} \dots (15), T I_N^{(2)}(x_1, \dots, x_n) = \frac{n}{2} (1 + \log 2\pi V) + \frac{1}{2} \log (1 + \frac{V}{V_0}) \dots (16)$ で与えられ、また指数情報に関するもとのまでの展開は近似的に、 $I_E^{(2)}(x_n) = 1 + \log \bar{x} \dots (17), T I_E^{(2)}(x_1, x_2, \dots, x_n) = n(1 + \log \bar{x}) \dots (18)$ で与えられる。ところで問題は新設地点の V_0, V, \bar{x} の与え方である。いくつも量的効果としてある V, \bar{x} の推定が重要となる。既存データがある場合には、1) 既設地点の値を代表する、2) 既設観測所の値から得た新設地點の値を外挿する、3) 地形、気象因子からの回帰構造をもとに推定する、などの方法が考えられ、データが豊富なほど後の方針に依存するであろう。一方、対象区域にはほとんど既存データがない場合には、4) 地理的・気候的・地形的などの降水情報をもとに既存の経験・判断情報をもとにして推定せらるる考え方であろう。

4 降水観測網配置計画への応用

不確定な降水現象を的確に把握するためには、それ相当に密なる観測網を配置すればよいかであろうが、現実には経済的にも技術的にも効率とはいえない。ここでは前述の情報量概念を基礎に、最適な観測網配置計画の手順を概述する。手順1；まず、観測網配置計画における対象区域を図のようにn個のブロックに分割する。分割には各ブロック内に存在する既設観測所の総情報量が類似して、各区域を1つのブロックとして、情報量が多く得られる区域では観測所を密に、またそのブロックの面積が広い場合にはより多くの観測所が設置できるように全投資額をそのブロックの平均情報量と面積の積に比例するよう分割する。手順2；各ブロック内の基幹観測所を選ぶとともに、観測所が一様に分布するよう图のごとく新設したり廃止したりする。手順3；一様に分布された観測所に必要な費用が、そのブロックへの投資額より小さければ問題はないが、その逆の場合には、 $I_{k,E}^{(1)} - I_{k,E}^{(2)} / I_{k,E}^{(1)} < C_k$ となる基準のもとに観測所を廃止する。手順4； $\sum_{k=1}^{m_E} \{C_{k,E}^{(1)} S_{k,E}^{(1)} / (I_{k,E}^{(1)} (1 - S_{k,E}^{(1)})\}$
 $+ \sum_{k=m_E+1}^{m_E+m_N} \{C_{k,E}^{(2)} S_{k,E}^{(2)} / (I_{k,E}^{(2)} (1 - S_{k,E}^{(2)})\}$ ここで、 m_E, m_E+m_N は k ブロック内の既設観測所と新設観測所数、 $I_{k,E}^{(1)}, I_{k,E}^{(2)}, I_{k,E}^{(3)}$ は既設・廃止・新設情報量、 $C_{k,E}^{(1)}, C_{k,E}^{(2)}, C_{k,E}^{(3)}$ はそれぞれの費用、 $S_{k,E}^{(1)}$ は決定度数で、 $C_{k,E}^{(1)} = 1$ 、廃止推定は 50、 $C_{k,E}^{(3)}$ は k ブロックへの投資額である。

5 あとがき

本論文では情報量の展開式を説明したが、こうして理論的アプローチを琵琶湖流域にも適用していくので、時間が許すば講演時によべたい。

参考文献；1) 寺沢光一；情報決定理論序説、岩波書店、pp. 248~250, 1971.11.

