

極値統計量を用いたデータ領域の推定法について

Estimating the Data Region Using the Asymptotic Distributions of Extreme-value Statistics

渡辺一帆*

Kazuho Watanabe

渡辺澄夫†

Sumio Watanabe

Abstract: In the field of pattern recognition or outlier detection, it is desired to estimate the region where the data of a particular class are generated. In other words, precise prediction is realized by accurately estimating the support of the distribution that generates the data. Considering the 1-dimensional distribution whose support is a finite interval, the data region is characterized by the maximum value and the minimum value in the samples. Limiting distributions of these values have been studied in the extreme-value theory in statistics. In this research, we propose a method to estimate the data region using the maximum value and the minimum value in the samples. We calculate the average loss of the estimator, and derive the optimal estimators for given loss functions.

Keywords: data region, asymptotic distribution, extreme value statistics

1 まえがき

パターン認識や異常値の検出などの一つの方法として、ある特定のクラスのデータや正常なデータの具体例を用いて、それらのデータの発生する領域を推定することが行なわれる。データの存在する領域と存在しない領域との境界を得ることで、入力データの識別がおこなわれる。データがある確率分布にしたがって発生していると仮定すれば、その確率分布が正の値をとる範囲を正確に推測することによって、高精度な予測が実現される。

しかし、データを発生している確率分布がある有限の範囲でのみ正の値をとる場合、そのモデルの対数尤度は発散してしまうため、統計的推測の漸近理論における正則条件は成立しない。

この場合の統計的推測についても様々な研究がなされており、統計的正則モデルとはかなり異なる性質をもつことが明らかにされてきた [2]。

他方では、ある確率分布から得られるサンプルの最大

値、最小値等の性質は極値統計の理論で議論されてきた [1][3]。

本研究では、一次元のデータ、もしくは、高次元データの一次元の指標といった確率変数の確率分布の端点を推定することで、データの発生する領域を推定する方法を提案する。得られたサンプルの最大値、最小値に補正を加えて端点を推定する場合、極値統計に基づいて最大値、最小値の漸近分布を考えることで、予測損失を最小とするような補正を与えることができるることを示す。

まず第2章で極値統計の一般論として、最大値の漸近分布について述べ、第3章では、それに基づきデータの発生領域の推定法と、そのときの予測損失を導出する。第3章で述べる推定法は、データの確率分布についてのいくつかの仮定の下で導出される。そのため、この推定法を実際に用いるには、他の推定しなければならないパラメータが存在する。そこで、第4章において、それらのパラメータの推定法を与える。第5章で数値実験により、第3章の理論解析の結果と第4章の他のパラメータの推定法の検証を行なう。

得られる結果は1次元の確率分布についてのものであるが、高次元のデータについても様々な1次元の指標を考えると、この方法を適用することが考えられる。これについては第6章で考察を行ない、高次元データへ適用する場合に必要となる今後の課題について述べる。

*東京工業大学大学院 総合理工学研究科 電子機能システム専攻,
〒 226-8503 横浜市緑区長津田 4259, tel. 045-924-5018, e-mail
kazuho23@pi.titech.ac.jp,
Department of Advanced Applied Electronics, Tokyo Institute
of Technology, 4259 Nagatsuda, Midori-ku, Yokohama, 226-8503
Japan

†東京工業大学 精密工学研究所
P&I Lab., Tokyo Institute of Technology, 4259 Nagatsuda,
Midori-ku, Yokohama, 226-8503 Japan

2 極値統計量と漸近分布

互いに独立に同じ分布(密度関数を $f(x)$, 累積分布関数を $F(x)$ とする)に従う n 個のサンプル X_1, X_2, \dots, X_n を, 大きさの順に並べ換え,

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$$

としたときの, k 番目の値で決まる確率変数 $X_{(k)} (1 \leq k \leq n)$ を順序統計量という。最小値 $\min_{1 \leq i \leq n} X_i$, 最大値 $\max_{1 \leq i \leq n} X_i$ は特に極値統計量と呼ばれる。ここでは特に最大値 $M_n = \max_{1 \leq i \leq n} X_i$ のみを扱う。最小値 $\min X_i$ についても同様なことが成り立つ。

M_n の分布関数は,

$$\begin{aligned} P\{M_n \leq x\} &= P\{X_1 \leq x, \dots, X_n \leq x\} \\ &= F(x)^n \end{aligned}$$

で与えられる。 M_n の密度関数 $f_{max}(x)$ は, この分布関数を微分して,

$$f_{max}(x) = nf(x)F(x)^{n-1}$$

となる。

$M_n = \max_{1 \leq i \leq n} X_i$ の分布関数 $F(x)^n$ の $n \rightarrow \infty$ での漸近分布について以下のことが知られている。

数列 $a_n (> 0), b_n$ を用いて,

$$a_n(M_n - b_n)$$

の分布関数がある分布関数 $G(x)$ に収束する場合, $G(x)$ は, 次の 3 種類の形に限られることが知られている。

$$1. \quad G(x) = \exp(-e^{-x}) \quad -\infty < x < \infty$$

$$2. \quad G(x) = \begin{cases} 0 & (x \leq 0) \\ \exp(-x^{-\alpha}) & (x > 0) \end{cases}$$

$$3. \quad G(x) = \begin{cases} \exp(-(-x)^\alpha) & (x \leq 0) \\ 1 & (x > 0) \end{cases}$$

(ここで α はある正の実数)

最小値 $\min_{1 \leq i \leq n} X_i$ についても同様なことが言えて, 対応する 3 種類の分布関数が知られている。

3 データ発生領域の推定法

n 個のデータ X_1, X_2, \dots, X_n が確率密度関数 $f(x)$ にしたがって得られたとする。 $f(x)$ の累積分布関数を $F(x)$ とする。確率密度関数 $f(x)$ は以下の条件を満たすとする。

$$(i) \quad \begin{cases} f(x) > 0 & (b < x < a) \\ f(x) = 0 & (\text{その他}) \end{cases}$$

(ii) $0 < \alpha, \beta < \infty, 0 < A, B < \infty$ に対し,

$$\lim_{x \rightarrow a-0} (a-x)^{1-\alpha} f(x) = A$$

$$\lim_{x \rightarrow b+0} (x-b)^{1-\beta} f(x) = B$$

このとき, 分布の端点である a, b を,

$$\hat{a} = \max_{1 \leq i \leq n} X_i + \frac{c_a}{n^{1/\alpha}}$$

$$\hat{b} = \min_{1 \leq i \leq n} X_i - \frac{c_b}{n^{1/\beta}}$$

を用いて推定する。

このときの予測損失を評価することで, 予測損失が最小になるように c_a と c_b を決めることを考える。推定量 \hat{a}, \hat{b} の性質はサンプルの最大値および最小値の性質によって決まるので, まずこれらの値の漸近分布について考察する。

定理 1 $M_n = \max_{1 \leq i \leq n} X_i, m_n = \min_{1 \leq i \leq n} X_i$ とするとき, $(\frac{A}{\alpha}n)^{1/\alpha}(M_n - a), (\frac{B}{\beta}n)^{1/\beta}(m_n - b)$ の漸近分布は, それぞれ

$$G_{\max}(x) = \begin{cases} \exp(-(-x)^\alpha) & (x \leq 0) \\ 1 & (x > 0) \end{cases}$$

$$G_{\min}(x) = \begin{cases} 0 & (x < 0) \\ 1 - \exp(-x^\beta) & (x \geq 0) \end{cases}$$

となる。

(定理 1 の証明)

$f(x)$ についての条件から $x = a$ の近傍で,

$$f(x) = A(a-x)^{\alpha-1} + o((a-x)^{\alpha-1})$$

$$1 - F(x) = \frac{A}{\alpha}(a-x)^\alpha + o((a-x)^\alpha)$$

と表せる。

$$u_n = \left(\frac{A}{\alpha}n\right)^{-1/\alpha} x + a$$

とおくと, $x \leq 0$ では,

$$\begin{aligned} &\Pr\left\{\left(\frac{A}{\alpha}n\right)^{1/\alpha}(M_n - a) \leq x\right\} \\ &= F(u_n)^n \\ &= \{1 - (1 - F(u_n))\}^n \\ &= \left\{1 - \frac{(-x)^\alpha}{n} + o\left(\frac{1}{n}\right)\right\}^n \\ &\rightarrow \exp(-(-x)^\alpha) \quad (n \rightarrow \infty) \end{aligned}$$

$x > 0$ では $1 - F(u_n) = 0$ となるので, $G_{\max}(x)$ が得られた. また, $G_{\min}(x)$ も同様にして得られる.

(定理 1 の証明終)

定理 2 $((\frac{A}{\alpha}n)^{1/\alpha}(M_n - a), (\frac{B}{\beta}n)^{1/\beta}(m_n - b))$ の分布関数を $G_n(s, t)$ とおくと,

$$\lim_{n \rightarrow \infty} G_n(s, t) = G_{\max}(s)G_{\min}(t)$$

となる.

(定理 2 の証明)

$$u_n = \left(\frac{A}{\alpha}n\right)^{-1/\alpha}s + a, \quad v_n = \left(\frac{B}{\beta}n\right)^{-1/\beta}t + b$$

とおくと,

$$\begin{aligned} & \Pr\left\{\left((\frac{A}{\alpha}n)^{1/\alpha}(M_n - a) \leq s, (\frac{B}{\beta}n)^{1/\beta}(m_n - b)\right) \leq t\right\} \\ &= F(u_n)^n - \{F(u_n) - F(v_n)\}^n \end{aligned} \quad (1)$$

定理 1 から

$$F(u_n)^n \rightarrow \exp(-(-s)^\alpha) \quad (n \rightarrow \infty)$$

であり,

$$\begin{aligned} & \{F(u_n) - F(v_n)\}^n \\ &= \{1 - (1 - F(u_n)) - F(v_n)\}^n \\ &= \left\{1 - \frac{(-s)^\alpha}{n} - \frac{t^\beta}{n} + o\left(\frac{1}{n}\right)\right\}^n \\ &\rightarrow \exp(-(-s)^\alpha - t^\beta) \quad (n \rightarrow \infty) \end{aligned}$$

よって,

$$G_n(s, t) \rightarrow \exp(-(-s)^\alpha)(1 - \exp(-t^\beta)) \quad (n \rightarrow \infty)$$

(定理 2 の証明終)

定理 2 から, 最大値 M_n と最小値 m_n は漸近的に独立になるので, それぞれの端点の推定は互いに独立して扱えばよい. そこで, 以降は端点 $b = 0$ として, 端点 a のみを推定するときの予測損失を考える. 予測損失として,

$$E_{X^n}[U(|a - \hat{a}|)] \quad (2)$$

を用いる. ここで, $E_{X^n}[\cdot]$ はサンプルの出方についての平均を表し, 関数 $U(x)$ は, $U(0) = 0$ を満たす任意の解析関数とする.

定理 3 k が奇数のとき, $n^{k/\alpha}(\hat{a} - a)^k$ の累積分布関数を $H_n(t)$ とおき, k を自然数とするとき, $n^{k/\alpha}|\hat{a} - a|^k$ の累積分布関数を $\bar{H}_n(t)$ とおくと,

$$\lim_{n \rightarrow \infty} H_n(t) = \begin{cases} 1 & (t \geq c_a^k) \\ \exp(-\frac{A}{\alpha}(c_a - t^{1/k})^\alpha) & (0 < t < c_a^k) \end{cases}$$

また,

$$\begin{aligned} & \lim_{n \rightarrow \infty} \bar{H}_n(t) \\ &= \begin{cases} 1 - \exp(-\frac{A}{\alpha}(c_a + t^{1/k})^\alpha) & (t \geq c_a^k) \\ \exp(-\frac{A}{\alpha}(c_a - t^{1/k})^\alpha) - \exp(-\frac{A}{\alpha}(c_a + t^{1/k})^\alpha) & (0 < t < c_a^k) \end{cases} \end{aligned}$$

である.

(定理 3 の証明)

$$\underline{t} = a - n^{-\frac{1}{\alpha}}(t^{\frac{1}{k}} + c_a)$$

$$\bar{t} = a - n^{-\frac{1}{\alpha}}(-t^{\frac{1}{k}} + c_a)$$

とおくと, $n^{k/\alpha}(\hat{a} - a)^k \leq t$ は, k が奇数のとき,

$$\max_{1 \leq i \leq n} X_i \leq \bar{t}$$

と同値であり, $n^{k/\alpha}|\hat{a} - a|^k \leq t$ は,

$$\underline{t} \leq \max_{1 \leq i \leq n} X_i \leq \bar{t}$$

と同値なので,

$$H_n(t) = \begin{cases} 1 & (t \geq c_a^k) \\ F(\underline{t})^n & (t < c_a^k) \end{cases}$$

$$\bar{H}_n(t) = \begin{cases} 1 - F(\underline{t})^n & (t \geq c_a^k) \\ F(\bar{t})^n - F(\underline{t})^n & (t < c_a^k) \end{cases}$$

である.

$x = a$ の近傍では,

$$1 - F(x) = \frac{A}{\alpha}(a - x)^\alpha + o((a - x)^\alpha)$$

と表せるので,

$$\begin{aligned} F(\underline{t})^n &= \left\{1 - \frac{1}{n} \frac{A}{\alpha}(t^{1/k} + c_a)^\alpha + o\left(\frac{1}{n}\right)\right\}^n \\ &\rightarrow \exp(-\frac{A}{\alpha}(c_a + t^{1/k})^\alpha) \quad (n \rightarrow \infty) \end{aligned}$$

$$\begin{aligned} F(\bar{t})^n &= \left\{1 - \frac{1}{n} \frac{A}{\alpha}(-t^{1/k} + c_a)^\alpha + o\left(\frac{1}{n}\right)\right\}^n \\ &\rightarrow \exp(-\frac{A}{\alpha}(c_a - t^{1/k})^\alpha) \quad (n \rightarrow \infty) \end{aligned}$$

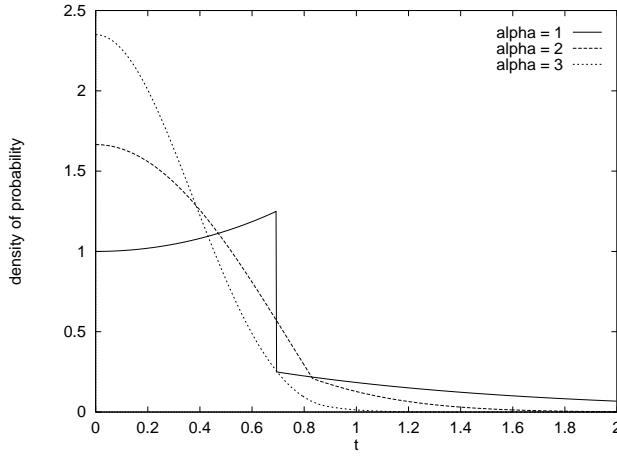


図 1: $n^{1/\alpha} |a - \hat{a}|$ の確率密度 ($\alpha = 1, 2, 3$)
より定理を得る。
(定理 3 の証明終)

$c_a = 0$ のとき、定理 3 の漸近分布はワイブル分布関数になる。

定理 3 の漸近分布を微分することで、 $n^{k/\alpha} |\hat{a} - a|^k$ の確率密度関数 $h_n(t)$ が得られる。 $k = 1$ としたときの $h_n(t)$ を $\alpha = 1, 2, 3$ の場合について図 1 に示す。ここで、最大値からの補正の係数である c_a の値は、後で述べるそれぞれの分布の平均を最小にするような c_a の値を用いた。

定理 3 で得られた漸近分布から平均を求めて、以下の定理を得る。

定理 4 k を自然数とするとき、

$$\begin{aligned} & \lim_{n \rightarrow \infty} E_{X^n} [n^{k/\alpha} (\hat{a} - a)^k] \\ &= c_a^k + \sum_{i=1}^k c_a^{k-i} \binom{k}{i} \left(\frac{\alpha}{A}\right)^{\frac{i}{\alpha}} \frac{i}{\alpha} (-1)^i \Gamma\left(\frac{i}{\alpha}\right) \end{aligned}$$

また、 k が奇数のとき、

$$\begin{aligned} & \lim_{n \rightarrow \infty} E_{X^n} [n^{k/\alpha} |\hat{a} - a|^k] \\ &= c_a^k + \sum_{i=1}^k c_a^{k-i} \binom{k}{i} \left(\frac{\alpha}{A}\right)^{\frac{i}{\alpha}} \frac{i}{\alpha} (-1)^i \left\{ 2\gamma\left(\frac{i}{\alpha}, \frac{A}{\alpha} c_a^\alpha\right) - \Gamma\left(\frac{i}{\alpha}\right) \right\} \end{aligned}$$

ここで、 $\gamma(x, p)$ と、 $\Gamma(x)$ は不完全ガンマ関数とガンマ関数で、その定義式は、

$$\gamma(x, p) = \int_0^p t^{x-1} e^{-t} dt, \quad \Gamma(x) = \int_0^\infty t^{x-1} e^{-t} dt$$

である。

(定理 4 の証明)

k が奇数のとき、

$$\begin{aligned} & E_{X^n} [n^{k/\alpha} (\hat{a} - a)^k] \\ & \rightarrow c_a^k - \int_{-\infty}^{c_a} \exp\left(-\frac{A}{\alpha}(c_a - t^{1/k})^\alpha\right) dt \quad (n \rightarrow \infty) \\ &= c_a^k - \frac{k}{A} \int_0^\infty \left\{ c_a - \left(\frac{\alpha}{A} t\right)^{\frac{1}{\alpha}} \right\}^{k-1} \left(\frac{\alpha}{A} t\right)^{\frac{1}{\alpha}-1} e^{-t} dt \end{aligned}$$

また、 k を自然数とするとき、

$$\begin{aligned} & E_{X^n} [n^{k/\alpha} |\hat{a} - a|^k] \\ & \rightarrow c_a^k - \int_0^{c_a} \exp\left(-\frac{A}{\alpha}(c_a - t^{1/k})^\alpha\right) dt \\ & \quad + \int_0^\infty \exp\left(-\frac{A}{\alpha}(c_a + t^{1/k})^\alpha\right) dt \quad (n \rightarrow \infty) \\ &= c_a^k - \frac{k}{A} \int_0^{\frac{A}{\alpha} c_a^\alpha} \left\{ c_a - \left(\frac{\alpha}{A} t\right)^{\frac{1}{\alpha}} \right\}^{k-1} \left(\frac{\alpha}{A} t\right)^{\frac{1}{\alpha}-1} e^{-t} dt \\ & \quad + \frac{k}{A} \int_{\frac{A}{\alpha} c_a^\alpha}^\infty \left\{ \left(\frac{\alpha}{A} t\right)^{\frac{1}{\alpha}} - c_a \right\}^{k-1} \left(\frac{\alpha}{A} t\right)^{\frac{1}{\alpha}-1} e^{-t} dt \end{aligned}$$

ここで $(c_a - (\frac{\alpha}{A} t)^{\frac{1}{\alpha}})^{k-1}$ を 2 項展開して得られる。
(定理 4 の証明終)

定理 4 から (2) 式の予測損失について、次の 2 つの系が得られる。

系 1 $a_1 = \frac{\partial U(0)}{\partial x} \neq 0$ のとき

$$\begin{aligned} & E_{X^n} [U(|a - \hat{a}|)] \\ &= \frac{a_1}{n^{1/\alpha}} \left[c_a - \left(\frac{\alpha}{A}\right)^{\frac{1}{\alpha}} \frac{1}{\alpha} \left\{ 2\gamma\left(\frac{1}{\alpha}, \frac{A}{\alpha} c_a^\alpha\right) - \Gamma\left(\frac{1}{\alpha}\right) \right\} \right] + o\left(\frac{1}{n^{1/\alpha}}\right) \end{aligned}$$

また、これを最小にする c_a を c_a^* と表すと、

$$c_a^* = \left(\frac{\alpha}{A} \log 2\right)^{\frac{1}{\alpha}}$$

である。

(系 1 の証明)

$$U(|a - \hat{a}|) = a_1 |a - \hat{a}| + O(|a - \hat{a}|^2)$$

より、定理 4 で $k = 1$ とすればよい。また、 c_a^* は、

$$\frac{\partial \gamma(x, p)}{\partial p} = p^{x-1} e^{-p}$$

であることを用いて、予測損失を c_a について微分して得られる。

系 2 $a_1 = \frac{\partial U(0)}{\partial x} = 0$, $a_2 = \frac{1}{2} \frac{\partial^2 U(0)}{\partial x^2} \neq 0$ のとき

$$\begin{aligned} & E_{X^n} [U(|a - \hat{a}|)] \\ &= \frac{a_2}{n^{2/\alpha}} \left\{ c_a^2 - 2 \left(\frac{\alpha}{A}\right)^{\frac{1}{\alpha}} \frac{1}{\alpha} \Gamma\left(\frac{1}{\alpha}\right) c_a + \left(\frac{\alpha}{A}\right)^{\frac{2}{\alpha}} \frac{2}{\alpha} \Gamma\left(\frac{2}{\alpha}\right) \right\} + o\left(\frac{1}{n^{2/\alpha}}\right) \end{aligned}$$

また,

$$c_a^* = \left(\frac{\alpha}{A}\right)^{\frac{1}{\alpha}} \frac{1}{\alpha} \Gamma\left(\frac{1}{\alpha}\right)$$

である。

(系 2 の証明)

$$U(|a - \hat{a}|) = a_2 |a - \hat{a}|^2 + O(|a - \hat{a}|^3)$$

より, 定理 4 で $k = 2$ とすればよい。

4 他のパラメータの推定法

これまで述べたデータの発生領域の推定法においては, データを発生している確率密度関数 $f(x)$ について, 定数 α, β, A, B は与えられたものとして最適な推定法を導出した。これらの定数は確率密度関数 $f(x)$ の端点付近の変化によって決まるもので, 実際にデータのみから領域を推定する場合は, これらの定数も推定する必要がある。

k 個のデータ中の最大値の漸近分布は, 前章の条件における定数 α と A , および端点 a をパラメータとして持つ分布として表され, その密度関数を $p_k(x|\alpha, A, a)$ で表すと,

$$p_k(x|\alpha, A, a) = Ak(a-x)^{\alpha-1} \exp\left(-\frac{Ak}{\alpha}(a-x)^\alpha\right) \quad (3)$$

である。また, この最大値の分布から m 個のデータ x_1, x_2, \dots, x_m が与えられたときの対数尤度 $L(\alpha, A, a)$ は,

$$L(\alpha, A, a) = \sum_{i=1}^m \left\{ \log Ak + (\alpha-1) \log(a-x_i) - \frac{Ak}{\alpha} (a-x_i)^\alpha \right\} \quad (4)$$

である。

確率密度関数 $f(x)$ にしたがって得られた n 個のデータを n/m 個ごとに分割し, それぞれの分割中の最大値を求めるとき, それらの最大値は, (3)式の分布にしたがっているとみなせる。したがって, (4)式で $k = n/m$ とした対数尤度を最大化することで, パラメータ α, A を推定することができる。パラメータ β, B についても最小値の分布から同様に推定することができる。

前章では, パラメータ α, A が与えられたとき, 分布の端点を,

$$\hat{a} = \max_{1 \leq i \leq n} X_i + \frac{c_a}{n^{1/\alpha}}$$

によって推定した。前章の系 1 および系 2 より, 予測損失を最小化する c_a^* は, α と A を用いて表すことができる。そこで, (4) 式のパラメータ a を, この \hat{a} に置き換える, 前章の系における c_a^* を用いて,

$$a = \max_{1 \leq i \leq n} X_i + \frac{c_a^*}{n^{1/\alpha}} \quad (5)$$

とすることで, パラメータ a をパラメータ α, A の関数として表すと, (4) 式の対数尤度は, α, A の関数として表すことができる。

こうして得られた対数尤度 $L(\alpha, A)$ を, 繰り返し法によって最大化することで, パラメータ α, A を推定することができる。このとき, 繰り返し法に必要な $L(\alpha, A)$ の勾配 $(\frac{\partial L}{\partial \alpha}, \frac{\partial L}{\partial A})$ は,

$$\begin{aligned} \frac{\partial L}{\partial \alpha} &= \sum_{i=1}^m \left[\left\{ 1 - \frac{Ak}{\alpha} (a-x_i)^\alpha \right\} \log(a-x_i) + \frac{Ak}{\alpha^2} (a-x_i)^\alpha \right. \\ &\quad \left. + \frac{1}{a-x_i} \left\{ \alpha - 1 - Ak(a-x_i)^\alpha \right\} \frac{\partial a}{\partial \alpha} \right] \\ \frac{\partial L}{\partial A} &= \sum_{i=1}^m \left[\left\{ \frac{1}{A} - \frac{k}{\alpha} (a-x_i)^\alpha \right\} \log(a-x_i) \right. \\ &\quad \left. + \frac{1}{a-x_i} \left\{ \alpha - 1 - Ak(a-x_i)^\alpha \right\} \frac{\partial a}{\partial A} \right] \end{aligned}$$

である。ここで, (5) 式において, $E_{X^n}[|\hat{a} - a|]$ を最小にする c_a^* を用いると,

$$\begin{aligned} \frac{\partial a}{\partial \alpha} &= \frac{1}{\alpha^2} \left\{ 1 - \log \frac{\alpha \log 2}{An} \right\} \left(\frac{\alpha}{An} \log 2 \right)^{\frac{1}{\alpha}} \\ \frac{\partial a}{\partial A} &= -\frac{1}{\alpha A} \left(\frac{\alpha}{An} \log 2 \right)^{\frac{1}{\alpha}} \end{aligned}$$

である。

5 数値実験

上記の推定法の適用例として,

$$f(x) = \begin{cases} 1 & (0 < x < 1) \\ 0 & (\text{その他}) \end{cases}$$

のとき, 確率密度関数 $f(x)$ に従う n 個のサンプルから, 分布の端点 $a = 1.0$ の推定を行なった。この場合は $\alpha = A = 1.0$ であり, この α, A が既知のときは, $E_{X^n}[|\hat{a} - a|]$ を最小にするような推定量 \hat{a} は,

$$\hat{a} = \max_{1 \leq i \leq n} X_i + \frac{\log 2}{n}$$

で与えられる。サンプル数 $n = 10000$ として, まず初めに, この推定量 \hat{a} を用いて分布の端点 $a = 1.0$ の推定を行なった。

次に, 第 4 章で述べた方法によって, パラメータ α, A も同時に推定し, 端点 a の推定を行なった。このとき, 10000 個のサンプルを 100 個ずつに分割し, 最大値の分布に従うサンプル 100 個を用いて, α, A の推定を行なった。

$n(a - \hat{a})$ と $n|a - \hat{a}|$ の平均値について, それぞれ, 理論値, α, A が既知としたときの実験結果 (α, A :known),

	理論値	α, A :known	α, A :unknown
$n(a - \hat{a})$	0.306	0.321(0.998)	0.322(1.060)
$n a - \hat{a} $	0.693	0.703(0.777)	0.760(0.806)

表 1: 実験結果 ($\alpha = A = 1.0$ のとき)

	理論値	α, A :known	α, A :unknown
$\sqrt{n}(a - \hat{a})$	0.053	0.061(0.463)	0.026(0.715)
$\sqrt{n} a - \hat{a} $	0.371	0.373(0.282)	0.572(0.430)

表 2: 実験結果 ($\alpha = A = 2.0$ のとき)
 α, A も同時に推定したときの実験結果 (α, A :unknown) を表 1 に示す (括弧内は標準偏差).

また,

$$f(x) = \begin{cases} 2 - 2x & (0 < x < 1) \\ 0 & (\text{その他}) \end{cases}$$

の場合に, $a = 1.0$ の推定を行なった. このとき, $\alpha = A = 2.0$ であり, $E_{X^n}[\hat{a} - a]$ を最小にするような推定量 \hat{a} は,

$$\hat{a} = \max_{1 \leq i \leq n} X_i + \sqrt{\frac{\log 2}{n}}$$

で与えられる. この場合も上と同様に, α, A が既知とした場合と, これらも同時に推定した場合について実験を行なった結果を表 2 に示す.

これらの実験結果から, α, A が既知とすると, 理論値とほぼ一致していることが確かめられた. また, α, A も同時に推定すると, その分, 推定誤差は大きくなるが, $\alpha = A = 1$ の時は, α, A が既知とした場合とほぼ同様の結果が得られているのがわかる.

6 考察

データが発生する領域が有限の場合に, その領域の推定法として, 一次元の確率分布について, その端点を推定する方法を与えた. 一次元の確率分布の端点の推定においては, 得られたデータの最大値や最小値を用いた推定法を考えると, 極値統計学に基づいて, それらの漸近分布を考察することで, 予測損失を最小にするような補正を与えることができるることを示した. ここでは一次元の確率分布について, その端点を推定することでデータの発生する領域を推定する方法を与えたが, 一般の高次元のデータについても何らかの一次元の指標についてはこの方法を適用することができる. いくつかの指標を用いることで高次元のデータの発生する領域の推定を行なうことも可能である.

また, これまでの議論では, 損失関数として $U(|\hat{a} - a|)$ を評価し, この損失に対し最適な推定法を導出したが,

端点を過大に推定するのと, 過小に推定する場合で損失が異なるような場合にも, 同様な議論により損失を最小化する推定法を導くことができる. l_1, l_2 を正の定数とし, 関数 $L(x)$ を,

$$L(x) = \begin{cases} -l_1 x & (x < 0) \\ l_2 x & (x \geq 0) \end{cases}$$

とすると, 予測損失として, $E_{X^n}[L(\hat{a} - a)]$ を用いた場合に, 同様の議論から次の定理が成り立つ.

定理 5 X_1, \dots, X_n は, 確率分布 $f(x)$ から独立に得られたとする. また密度関数 $f(x)$ は, 第3章の条件 (i), (ii) を満たすとする. このとき,

$$E_{X^n}[L(\hat{a} - a)] = \frac{l_2}{n^{\frac{1}{\alpha}}} \left[c_a - \left(\frac{\alpha}{A} \right)^{\frac{1}{\alpha}} \frac{1}{\alpha} \left\{ \left(1 + \frac{l_1}{l_2} \right) \gamma \left(\frac{1}{\alpha}, \frac{A}{\alpha} c_a^\alpha \right) - \Gamma \left(\frac{1}{\alpha} \right) \right\} \right] + o \left(\frac{1}{n^{\frac{1}{\alpha}}} \right)$$

であり, これを最小にする c_a を c_a^* とすると,

$$c_a^* = \left(\frac{\alpha}{A} \log \left(1 + \frac{l_1}{l_2} \right) \right)^{\frac{1}{\alpha}}$$

である.

本研究では 1 次元の確率分布の端点の推定に, 得られたデータの最大値および最小値のみを用いたが, 端点を推定する方法は他にも様々なものが考えられる. ここで提案した推定法を他の推定法と比較することは今後の課題である.

7 おわりに

データの発生する領域の推定法として, 1 次元の確率分布から得られたデータの最大値, 最小値を用いた推定法を提案した. データの最大値, 最小値の漸近分布を導出し, 予測損失を最小にするような推定法を与えた.

参考文献

- [1] M.R.Leebetter, G.Lindgren, H.Rootzen "Extremes and Related Properties of Random Sequences and Processes", Springer-Verlag, New York Heidelberg Berlin, 1983.
- [2] M.Akahira, K.Takeuchi "Non-Regular Statistical Estimation", Springer-Verlag, New York, 1995.
- [3] E.J.Gumbel(河田竜夫, 岩井重久, 加瀬滋男監訳) "極値統計学", 生産技術センター社, 1962.
- [4] 渡辺一帆, 渡辺澄夫, "極値統計量を用いたデータ発生領域の学習法," 信学技報, NC2003-30, 2003.