

確率的計画法とサンプル情報

森田 浩

1. はじめに

われわれが意思決定を行なうときには、さまざまな制約条件とともに不確実性も考慮しなければならないことが多い。したがって、計画問題がいろいろな分野で応用される時、その大部分のものは係数のいずれかの中に不確実性を含んでいることになる。この不確実性を確率的な変動として扱っているのが確率的計画法である。標本空間 Ω と A 上の確率測度 P をもつ確率空間 (Ω, A, P) を考えるとき、確率的計画法の一般形は次のような期待値関数によって表わすことができる。

$$(1) \begin{cases} \text{最小化} & E\{f_0(x, \omega)\} = \int_{\Omega} f_0(x, \omega) P(d\omega), \\ \text{条件} & E\{f_i(x, \omega)\} = \int_{\Omega} f_i(x, \omega) P(d\omega) \leq 0, \\ & i=1, 2, \dots, m, \\ & x \in X \subset R^n, \omega \in \Omega. \end{cases}$$

ただし X は R^n の閉部分集合であり、 $f_0: R^n \times \Omega \rightarrow R \cup \{-\infty, +\infty\}$ と $f_i: R^n \times \Omega \rightarrow R, i=1, 2, \dots, m$ はランダム下半連続関数である。この一般形は確率的計画法の等価確定モデルとして広く使われているリコースモデルや機会制約条件モデルなども含んでいる[7]。 P が既知ならば問題(1)は定義可能だが、多くの実際の問題では P についての完全情報が与えられるとは必ずしも限らない。つまり確率変動に関する不完全情報のもとでの確率的計画問題を考えなければならないことが起こるのである。

このような状況で問題(1)の最適解を求めるための1つの方法は、観測値データにもとづいて求められた P の推定値あるいは近似値を P の代わりに用い、そのときに得られる確率的計画問題の最適解から推定する方法である。大きさ $\nu (< \infty)$ のサンプルにもとづいて求められた P の推定値を P^ν とするとき、不完全情報のもとでの確率的計画問題

$$(2) \begin{cases} \text{最小化} & E^\nu\{f_0(x, \omega)\} = \int_{\Omega} f_0(x, \omega) P^\nu(d\omega), \\ \text{条件} & E^\nu\{f_i(x, \omega)\} = \int_{\Omega} f_i(x, \omega) P^\nu(d\omega) \leq 0, \end{cases}$$

もりた ひろし 大阪市立大学 商学部

〒558 大阪市住吉区杉本 3-3-138

$$\begin{cases} i=1, 2, \dots, m, \\ x \in X \subset R^n, \omega \in \Omega. \end{cases}$$

が得られるが、この問題(2)の最適解から問題(1)の最適解を推定しようとするのである。この方法においては、得られたサンプルは問題(1)の最適解を推定するにあたってどの程度の価値を持っているのか、サンプルの大きさはいくつにするのが適当か、問題(1)と問題(2)の最適解にどのような関係があるか、などといったことに興味を持たれるであろう。

確率的計画法におけるサンプル情報の価値の考え方は Bracked & Soland [2] が示し、さらに Jagannathan [8] がリコースモデルと機会制約条件モデルに対するサンプル情報の価値、およびそれにもとづく最適サンプル数について示している。また不完全情報のもとでの“最適解”を与えるいくつかの確率計画モデルも確率的線形計画問題に対して提案されている。真の最適解あるいは最適値の取り得る範囲の予測 [3]、ゲーム理論的なミニマックスアプローチ [4, 10] などである。さらにサンプル数が十分に大きくなったとき、ある条件下で問題(2)の最適解が問題(1)の最適解に収束すること [5, 6] や逐次的にサンプルが得られる場合の adaptive な確率計画モデル [9] などの提案もなされている。

本稿ではここに挙げた確率計画モデルの中から、サンプル情報を取り入れたいくつかの確率的線形計画モデルを紹介する。

2. ミニマックスアプローチ

次の線形計画問題(3)において、いくつかの係数が確率変数であるとする。

$$(3) \begin{cases} \text{最大化} & c'x, \\ \text{条件} & Ax=b, x \geq 0. \end{cases}$$

ここで A は $m \times n$ 行列、 b は m 次元列ベクトル、 c と x は n 次元列ベクトルである。非負で凸のリコース関数を ϕ とするとき、問題(3)のリコースモデルは次のようになる。

$$(4) \text{最大化 } E_P\{c'x - \phi(x; A, b)\}.$$

確率変数の分布 F が既知であれば、問題(4)を非線形の

確定問題として扱うことができるが、ここでは分布 F について不完全な情報しか与えられていない場合を考える。すなわち、不完全情報のために、分布 F については“ある分布の集合 \mathcal{F} に属している”ということだけしかわかっていないものとする。簡単のため b のみが確率変数であるとすると、たとえば、集合 \mathcal{F} はサンプル情報にもとづいて、(5)式のようにモーメント値を規定することによって定義されたり [4]、(6)式のように分布 F がある特定の分布形にしたがうということだけがわかっているときにその分布パラメータを推定することによって定義されたりする [9]。

$$(5) \quad \mathcal{F} = \{F | E_F b_i = \mu_i, V_F b_i = \sigma_i^2, 1 \leq i \leq m\}$$

$$(6) \quad \mathcal{F} = \{F | (\mu, \sigma^2) \in S_\alpha, F \text{ は正規分布}\}$$

ここで、 μ_i と σ_i^2 はサンプルから計算された b_i の平均と分散で、 S_α は正規分布の分布パラメータの信頼領域（信頼係数 α ）である。この $F \in \mathcal{F}$ なる条件のもとで、次のミニマックス問題(7)の最適解を問題(4)に対するミニマックス解と呼ぶ。

$$(7) \quad \text{最大化} \quad \min_{F \in \mathcal{F}} E_F \{c'x - \phi(x; A, b)\}.$$

ミニマックス解は、直面している不確実性の状況において想定される最悪の状況下で最適化された解であると見ることができる。

(5)式の集合 \mathcal{F} に対するミニマックス問題(7)はモーメント問題と呼ばれている。これは確率変数の分布形がわかっていないとき、平均や分散などのモーメント値をサンプル情報から与えることで分布 F の属している集合 \mathcal{F} を定めるモデルである。このとき、規定されたモーメントの数を k とすると、いわゆる“最悪の分布 F^* ”は高々 $k+1$ 個の点の離散分布となる [4]。例として、 b のみを確率変数とした単純リコース問題を考えると、リコース関数は次のように与えられる。

$$(8) \quad \phi(x; b) = \sum_{i=1}^m w_i (A_i x - b_i)^+, \quad w_i \geq 0$$

ただし、 $(x)^+ = \max(x, 0)$ 、 A_i は A の第 i 行ベクトルである。このとき問題(7)における決定変数 x に関する最大化と分布 F に関する最小化の操作の交換が可能となり、さらにリコース関数の値の“最悪の場合”の期待値は次のような凸関数となる。

$$(9) \quad \max_{F \in \mathcal{F}} E_F \phi(x; b) =$$

$$\sum_{i=1}^m \frac{w_i}{2} \left\{ \sqrt{\sigma_i^2 + (A_i x - \mu_i)^2} - (A_i x - \mu_i) \right\}$$

(6)式の集合 \mathcal{F} に対するミニマックス問題(7)では、確率変数の分布形がたとえば正規分布というようにわかっ

ているとき、まずサンプル情報からその分布パラメータ（平均と分散）を推定する。そして分布パラメータをある信頼係数で推定された信頼領域に制限することで、分布 F の属している集合 \mathcal{F} を定める。例として、 b のみを確率変数とした2次リコース問題を考えると、リコース関数(10)およびその期待値(11)は次のように与えられる。

$$(10) \quad \phi(x; b) = \sum_{i=1}^m w_i (A_i x - b_i)^2, \quad w_i \geq 0,$$

$$(11) \quad E_F \phi(x, b) = \sum_{i=1}^m w_i \{ (A_i x - \mu_i)^2 + \sigma_i^2 \}$$

正規分布に対しては平均 μ と分散 σ^2 の信頼領域は

$$(12) \quad S_\alpha = \{(\mu_i, \sigma_i^2), i=1, 2, \dots, m\}$$

$$\begin{aligned} \sum_{i=1}^m \frac{(\mu_i - \bar{\mu}_i)^2}{s_i^2} &\leq \frac{m(N-1)}{N(N-m)} F_{\alpha/2}(m, N-m), \\ \frac{(N-1)s_i^2}{\chi_{\beta/2}^2(N-1)} &\leq \sigma_i^2 \leq \frac{(N-1)s_i^2}{\chi_{1-\beta/2}^2(N-1)}, \\ &i=1, 2, \dots, m. \end{aligned}$$

となる。ただし、 N はサンプル数、 $\bar{\mu}$ と s^2 はサンプル平均とサンプル分散、 $F_{\alpha}(m, n)$ は自由度対 (m, n) の F 分布の $\alpha\%$ 点、 $\chi_{\beta}^2(n)$ は自由度 n のカイ2乗分布の $\beta\%$ 点 ($\alpha = \beta^{1/m}/2$) である。このときリコース関数の値の“最悪の場合”の期待値は

$$(13) \quad \max_{F \in \mathcal{F}} E_F \phi(x; b) =$$

$$\sum_{i=1}^m w_i \left\{ \left(\frac{\lambda(A_i x - \bar{\mu}_i)}{\lambda - w_i s_i^2} \right)^2 + \frac{(N-1)s_i^2}{\chi_{1-\beta/2}^2(N-1)} \right\}$$

となるが、かつこの第2項は決定変数 x によらない定数であるから、以下のミニマックス問題では省略することができる。ただし、 λ はラグランジュ乗数で次の式を満足していなければならない。

$$(14) \quad \sum_{i=1}^m \frac{w_i^2 s_i^2 (A_i x - \bar{\mu}_i)^2}{(\lambda - w_i s_i^2)^2} =$$

$$\frac{m(N-1)}{N(N-m)} F_{\alpha/2}(m, N-m)$$

$$\lambda > \max_{i \in I} w_i s_i^2, \quad I = \{i | A_i x - \bar{\mu}_i \neq 0\}$$

このときミニマックス解を与える問題

$$(15) \quad \begin{cases} \text{最大化} & c'x - \sum_{i=1}^m w_i \left(\frac{\lambda(A_i x - \bar{\mu}_i)}{\lambda - w_i s_i^2} \right)^2, \\ \text{条件} & (14). \end{cases}$$

は凸計画とはならないが、 $\lambda \geq 3/2 \lambda_{\max}$ (λ_{\max} は $w_i s_i^2$ の最大値)に限れば x と λ に関する凸計画となる。また、 λ をパラメータとみたとき、問題(15)は x に関する凸計画となり、その時の最適解 $x^*(\lambda)$ は λ に関して連続性を持つ。以上から、数値解法によりミニマックス解 $x^*(\lambda^*)$

を求めることができる [10].

確率的線形計画問題で信頼領域を用いて集合 \mathcal{S} を定めるミニマックスモデルは、目的関数の係数を推定する問題 [11] や制約式の係数行列の中にある未知係数を推定する問題 [12] についても考察されている。

3. 最適解の推定

問題(2)の最適解 x^ν はサンプルの大きさ ν が大きくなるにつれて問題(1)の最適解 x^* に収束することが望まれる。次の定理は、問題 $\min E^\nu\{f(x, \omega)\}$ の最適解 x^ν が問題 $\min E\{f(x, \omega)\}$ の最適解 x^* に収束することに関するものである。

定理 1 [6] すべての $x \in X$ に対して $\omega \mapsto f(x, \omega)$ が Ω 上の連続関数であり、かつ、すべての $\omega \in \Omega$ に対して $x \mapsto f(x, \omega)$ が R^n 上の下半連続関数であるとする。さらに、サンプリングによって得られる測度 P^ν の列 $\{P^\nu\}_{\nu=0}^\infty$ が P に分布収束し、かつ、 $f(x, \cdot)$ -tight である、すなわち、すべての $x \in X$ と $\epsilon > 0$ に対して

$$(16) \int_{\Omega \setminus K_\epsilon} |f(x, \omega)| P^\nu(d\omega) < \epsilon, \quad \nu = 0, 1, \dots$$

となるコンパクト集合 $K_\epsilon \subset \Omega$ が存在するとする。このとき

$$(17) \int_{\Omega} f(x, \omega) P(d\omega) = \text{epi-lim}_{\nu \rightarrow \infty} \int_{\Omega} f(x, \omega) P^\nu(d\omega)$$

が得られる¹⁾。また

$$(18) \arg \min_{\Omega} \int_{\Omega} f(x, \omega) P^\nu(d\omega) \cap D \neq \emptyset \quad (a.s.)$$

$$(19) \{x^*\} = \arg \min_{\Omega} \int_{\Omega} f(x, \omega) P(d\omega) \cap D$$

であるコンパクト集合 $D \cap R^n$ が存在すれば

$$(20) x^* = \lim_{\nu \rightarrow \infty} x^\nu$$

$$(21) \inf_{\Omega} \int_{\Omega} f(x, \omega) P(d\omega) = \lim_{\nu \rightarrow \infty} \left(\inf_{\Omega} \int_{\Omega} f(x, \omega) P^\nu(d\omega) \right) \quad (a.s.)$$

が得られる。

このような枠組みの中で、未知係数をサンプリングによって推定しながら真の最適解の見つける問題を以下に述べる [9]。次の線形計画問題(24)を考える。

$$(24) \begin{cases} \text{最小化} & c'x, \\ \text{条件} & Ax + b \leq 0. \end{cases}$$

ここで A と b は未知あるいは確実に知られていない係数であるとする。 A と b の真の値をそれぞれ A^* と b^* とするならば、 A と b は密度関数

$$(23) p(t) = \begin{cases} +\infty & t = (A^*, b^*) \\ 0 & t \neq (A^*, b^*) \end{cases}$$

をもつ一点分布にしたがう。 $\{x \mid A^*x + b^* \leq 0\} \neq \emptyset$ と仮定するとき、サンプル情報が得られる度に adaptive な方法で

$$(24) \begin{cases} \text{最小化} & c'x, \\ \text{条件} & E\{Ax + b\} \leq 0 \Leftrightarrow A^*x + b^* \leq 0 \end{cases}$$

の最適解を推定するのが目的である。

A と b の推定は多変量回帰分析によって行なう。サンプル点 x^k において正規分布にしたがう観測雑音 u^k を含んだ観測値 $y^k = Ax^k + b + u^k$ が得られたとき、 A と b の最尤推定量は $(\hat{A}, \hat{b})' = (X'X)^{-1}(X'Y)$ となる。ただし、 X はサンプル点の行列 ($\text{rank } X = n+1$)、 Y は観測値の行列である。大きさ ν のサンプルから求められる推定量 (\hat{A}, \hat{b}) の密度関数 $p^\nu(t)$ は多変量正規分布を表わし、サンプル数が十分大きくなったときその分散共分散行列が O に近づくならば、 $\lim_{\nu \rightarrow \infty} p^\nu(t) = p(t)$ となり、 (\hat{A}, \hat{b}) は (A^*, b^*) の一致推定量となる。大きさ ν のサンプルが得られているときの推定値を (A^ν, b^ν) と表わすと、問題(24)の最適解 x^* を推定するための問題は次のように表わされる。

$$(25) \begin{cases} \text{最小化} & c'x, \\ \text{条件} & E^\nu\{\hat{A}x + \hat{b}\} \leq 0 \Leftrightarrow A^\nu x + b^\nu \leq 0 \end{cases}$$

問題(25)の最適解 x^ν を求め、さらに新しいサンプルから更新される推定量が得られる度に問題(25)を解き、最適解を $x^{\nu+1}, x^{\nu+2}, \dots$ と求めてゆけば、問題(24)の最適解 x^* に収束する点列 $\{x^\nu\}$ が得られる。しかし、 x^* を求めるのが目的であるから、問題(25)の最適解を厳密に求めなくても、 x^* へ収束する点列 $\{\bar{x}^\nu\}$ が構成できれば十分である。さらに、 \bar{x}^ν が問題(25)に対して実行可能で x^* に近ければより好ましい。

\bar{x}^ν は問題(25)の実行可能解であるとする。 \bar{x}^ν をサンプル点として新たな観測値 $y^{\nu+1}$ が得られると、推定値は $(A^{\nu+1}, b^{\nu+1})$ と更新され、

$$(26) \begin{cases} \text{最小化} & c'x, \\ \text{条件} & E^{\nu+1}\{\hat{A}x + \hat{b}\} \leq 0 \Leftrightarrow A^{\nu+1}x + b^{\nu+1} \leq 0 \end{cases}$$

が得られる。問題(26)に対応して、 \bar{x}^ν から $\bar{x}^{\nu+1}$ を構成するために次の2種類のステップを考える。

1. 実行可能性のためのステップ

\bar{x}^ν は問題(26)に対して実行可能になるとは限らないので、その時には \bar{x}^ν を実行可能領域内の点 x_ν^* へ射影する。

2. 最適性のためのステップ

実行可能な点 x_ν^* から $\bar{x}^{\nu+1}$ を作る時、より最適解に近づくようにしたいので内点法のアルゴリズム (アフ

インスケーリング法)を用いて

$$(27) \quad \bar{x}^{\nu+1} = x_p^\nu + \alpha^\nu d^\nu$$

とする。ただし、 α^ν はステップ幅、 d^ν は方向ベクトルである。

アフィンスケーリング法では境界上にない内点が必要であるが、1.のステップで得られる点 x_p^ν は境界上に位置してしまう。問題(26)では期待値を取った関数が制約条件に使われているが、推定量 (\hat{A}, \hat{b}) は正規分布にしたがう確率変数であるため、 \bar{x}^ν が問題(26)に実行可能でなくても $\hat{A}\bar{x}^\nu + \hat{b} \leq 0$ となる確率は0ではない。このことから、点 \bar{x}^ν が $\hat{A}\bar{x}^\nu + \hat{b} \leq 0$ を満たすように確率変数 (\hat{A}, \hat{b}) の実現値 (\bar{A}, \bar{b}) を選ぶことは可能であり、この実現値を用いたときの実行可能領域が問題(26)の実行可能領域とできるだけ近くなるように (\bar{A}, \bar{b}) の値を選ぶようにする。簡単のため $\bar{A} = A^{\nu+1}$ と固定して、 \bar{b} のみを選ぶ場合を考えると、次の b に関する最小化問題によって決められる。

$$(28) \quad \begin{cases} \text{最小化} & (b - b^\nu)^T V[\hat{b}]^{-1} (b - b^\nu), \\ \text{条件} & A^{\nu+1} x^\nu + b \leq 0. \end{cases}$$

これは b の信頼領域の中に $A^{\nu+1} \bar{x}^\nu + \bar{b} \leq 0$ となる \bar{b} が含まれるようにするとき、その信頼領域の幅が最も小さくなるように \bar{b}^* を選んでいることを示している。このとき、問題(26)の実行可能領域を以下のように修正する。

$$(29) \quad \begin{cases} \{x \mid A_i^{\nu+1} x + \bar{b}_i^* \leq 0 \text{ for } i \in J, \\ A_i^{\nu+1} x + b_i^{\nu+1} - \epsilon \leq 0 \text{ for } i \in J', \\ A_i^{\nu+1} x + b_i^{\nu+1} \leq 0 \text{ for } i \notin J \cup J'\} \end{cases}$$

$$\text{ただし、} J = \{i \mid A_i^{\nu+1} x^\nu + b_i^{\nu+1} > 0, \bar{b}_i^* \neq b_i^{\nu+1}\},$$

$J' = \{i \mid A_i^{\nu+1} x^\nu + b_i^{\nu+1} \leq 0, A_i^{\nu+1} x_p^\nu + b_i^{\nu+1} = 0\}$ で、 ϵ は許容誤差とする。この修正された領域は、問題(26)の実行可能領域に射影された点 x_p^ν を実行可能な内点にするだけでなく、問題(26)の条件を推定量にもとづいて緩めていることになる。

図1に解法アルゴリズムを示している。収束性に関しては次の定理が成立する。

定理2 [9] 確率1で

$$(30) \quad \lim_{\nu \rightarrow \infty} \{x \mid E^\nu \{Ax + b\} \leq 0\} = \{x \mid E \{Ax + b\} \leq 0\}$$

が成立する。

定理3 [9] 確率1で

$$(31) \quad \lim_{\nu \rightarrow \infty} |c' \bar{x}^\nu - c' x^*| \rightarrow 0$$

となる。

procedure 最適解の推定:

begin

初期推定値 (A^ν, b^ν) と許容誤差 ϵ を与える;

x^ν を任意に与える;

repeat

begin

$\nu \leftarrow \nu + 1$ とする;

新しい観測値 (x^ν, y^ν) を得て、推定値を更新する;

if x^ν が実行可能でない

then ステップ1により x_p^ν と領域(29)を求める

else $x_p^\nu \leftarrow \bar{x}^\nu$ とする;

ステップ2により $\bar{x}^{\nu+1} \leftarrow x_p^\nu + \alpha^\nu d^\nu$ とする;

end

until $\|\alpha^k d^k\| < \nu$;

$\bar{x}^{\nu+1}$ が x^* の推定値となる;

end.

図1 解法アルゴリズム

4. おわりに

本稿では2つの話題を中心に確率的計画法における統計的手法について述べた。後者のモデルでは、推定のための問題(26)において機会制約条件を取り入れた問題を考えることによって、最適解の推定値の精度などの評価についても考察しているところである。また、このモデルは確率測度 P の近似を用いた近似解法 [1] とも密接に関連しており、より広範囲の問題への拡張も可能であると思われる。

参考文献

- [1] J. Birge and R. J-B Wets, Designing Approximation Schemes for Stochastic Optimization Problems, In Particular for Stochastic Programs with Recourse, *Mathematical Programming Study*, Vol.27, (1986), 54-102.
- [2] J. Bracken and R. M. Soland, Statistical Decision Analysis of Stochastic Linear Programming Problems, *Naval Research Logistics Quarterly*, Vol.13, (1966), 205-226.
- [3] T. Cipra, Prediction in Stochastic Linear Programming, *Kybernetika*, Vol.23, (1987), 214-226.

- [4] J. Dupačová, The Minimax Approach to Stochastic Programming and an Illustrative Application, *Stochastics*, Vol.20, (1987), 73-88.
- [5] J. Dupačová, Epi-consistency in Restricted Regression Models —The Case of a General Convex Fitting Function, (to appear)
- [6] J. Dupačová and R. J-B Wets, Asymptotic Behavior of Statistical Estimators and of Optimal Solutions for Stochastic Optimization Problems, *Annals of Statistics*, Vol.16, (1988), 1517-1549.
- [7] Yu. Ermoliev and R. J-B Wets, *Numerical Techniques for Stochastic Optimization*, Springer-Verlag, 1988.
- [8] R. Jagannathan, Use of Sample Information in Stochastic Recourse and Chance-Constrained Programming Models, *Management Science*, Vol.31, (1985), 96-108.
- [9] H. Morita and H. Ishii, A Stochastic Improvement Method for Stochastic Programming, (to appear).
- [10] H. Morita, H. Ishii and T. Nishida, Confidence Region Method for Stochastic Programming Problem, *Journal of Operations Research Society of Japan*, Vol.30, (1987), 218-230.
- [11] H. Morita, H. Ishii and T. Nishida, Stochastic Programming with Estimated Objective, *Technology Reports of the Osaka University*, Vol.39, (1989), 1-7.
- [12] H. Morita, H. Ishii and T. Nishida, Stochastic Linear Programming Problem with Partially Estimated Constraint, *Mathematica Japonica*, Vol.35, (1990), 551-559.

脚注 1) エピ収束: $g = \text{epi-lim } g^v$ (関数列 $\{g^v\}$ が g に エピ収束する) \Leftrightarrow

- x に収束するすべての点列 $\{x^v\}$ に対して
(A.1) $\liminf_{v \rightarrow \infty} g^v(x^v) \geq g(x)$
- x に収束するある点列 $\{x^v\}$ に対して
(A.2) $\limsup_{v \rightarrow \infty} g^v(x^v) \leq g(x)$

「論文・事例研究」の原稿募集!

ORの特徴は実践にあるといわれています。実践的な応用をぬきにした理論ということはORでは考えられません。本誌でも以前から会員の皆様からの事例研究の報告をお願いしてきましたが、まだ十分な成果をあげているとはいえません。

「論文・事例研究」は企業、研究所、大学等で実際に行なった事例を論文としてまとめたものを広く会員の皆様に紹介することを目的として作られた欄です。この論文は2人のレフリーによって正式に審査されますが、マネジメント、行政、工学等の広い分野において適用対象の新しさ、適用方法の新しさ、適用範囲の広さ等が論理的、科学的に論じられたものでありますならば、積極的に採用する方針です。皆様のご投稿をお願い申し上げます。

投稿要領: 学会原稿用紙36枚(25×12行)以内(図・表を含む)
(ワープロ可)投稿先はOR学会事務局OR誌編集委員会宛。

なお、原稿の他コピーを2部添付してください。

レフリー審査の結果、改訂をお願いしたり、採択されない場合があることをご確認ください。また、原稿は、採択・不採択にかかわらず、原本、コピーともお返しできません。(OR誌編集委員会)