

最適化手法のいろいろ

—総合報告—

慶應大・工・管理工学科

柳井 浩

はじめに

‘函数方程式の近似解法’というシンポジウムで最適化手法 — しかも、実際に計算機にかけて使う手法をテーマとして選んだのは、これらの手法を函数空間にやさなく述べて考えれば、たゞちに‘函数方程式’の解法にも役立てることがで
きると考えるからである。しかし、こゝでは手法の‘やさな
がし’を論ずることはせず、むしろ計算技術として使われて
いるものを直接そのままの形で列举して、その考え方、計算
手順として具体化するやり方を示し、今後‘函数方程式’の
近似解法のアルゴリズムを新しく作る上の参考としたい。

実際、‘方程式の解法’と‘最適化問題の解法’の間に密
接な関係がある。すなはち、最小点や最大点を求めるのに、
目的函数 $f(x)$ を微分してゼロとおくこと（古典的操作）を考
えれば、たゞちに

$$\text{grad } f(x) = 0$$

と、連立方程式が得られる。従って、この方程式が解ければよい。しかし、このように連立方程式は、普通、そう簡単には解けないので、最適化問題をこのような操作によって解くにせよ、連立方程式を解く近似的手法のどれかを動員しなければならないことになる。

また、逆に、

$$g_i(x) = 0 \quad i = 1, \dots, N$$

と、連立方程式を解く問題も

$$\sum_{i=1}^N g_i^2(x)$$

という函数の最小点を求める問題と関係がつく。従って、最適化問題を直接解く良い方法があれば、これと方程式の解法に応用する可能性が生れてくる。

現状まとめると、方程式の解法の方が何よりも伝統的な経験の蓄積があり、最適化手法の多くがこれに負っているといってよい。しかし、同時に、古典的な方程式の解法も、最適化問題という場所で考立を試してみると、直観的なイメージが鮮明になり、有限個の変数に関する方程式の解法と函数方程式の解法に‘やさなさ’場合の手がかりが得られることが少なくない。

また、一般に、最適化手法といえば、変数の領域と不等式で与え、その上で考立する方が正統的と考えられてゐる

したが、本稿では、上に述べたような理由から、制約条件は、原則的に考慮しないことにする。

アルゴリズムの設計と評価

本稿では、いくつかのアルゴリズムを列挙するわけであるが、その各々に対する評価は避けたい。これは、第1に、本稿の興味の対象が主に手法の基礎をなす考え方にあること、第2に、アルゴリズムの評価そのものがヨウめて困難だからである。そこで、こゝではたゞアルゴリズムの評価についてごく簡単な一般論だけを述べておこうことにする。

ごく常識的にいって、最適化手法のアルゴリズムを評価する場合には次の4点が問題になる。

- イ) 計算の簡単さ
- ロ) 計算のはやさ
- ハ) 計算の確実性
- ニ) 計算の融通性

これらは、勿論、独立したものではない。2~3説明を加えると、ハ)では、そのアルゴリズムによって得られた点が本当にその函数の最小(大)点をもつてゐるかいかなかが問題である。ニ)で問題にされるのは、そのアルゴリズムがとりあつかう3つの函数の範囲である。いかえれば、そのアルゴリズム

が特定のタイプの函数を頭において作られたものであっても、他のタイプの函数にも使えるかいかないか？あるには、多少の誤差を容認するにしたらどうかが問題にされる。

しかし、これら4項目も、アルゴリズムを設計する側と、使用する側では、考え方が微妙にくじかってくる。すなはち、設計する側では、

(a-1) 式の簡単さ

(a-2) iteration の回数

(a-3) exactness (finite quadratic convergence)

(a-4) 凸函数に対する収束性

(a-5) 収束の ‘order’

などを頭においているのに対し、使用する側では

(b-1) プログラムの簡単さ

(b-2) 計算時間

(b-3) 種々の ‘test function’ に対する成績

を頭においているといってよいだろう。なお、2~3の点は注釈を加えておくことにすると、(a-3) で exact であるが、目的函数の形が定符号の 2 次形式である場合に、計算誤差がない限り、有限回の iteration で最小(大)点に到達するようなアルゴリズムは exact あるいは finite quadratic convergent というのである。また、(a-4) で問題にされる点は

目的函数が最小点をもつ凸函数であるとき、そのアルゴリズムによって、(有限回あるのは無限回を向かず) iteration を行うことによって、最小点に収束するような点列が得られるか否かである。さらに、(a-5)は、iteration の回数と、それによつて得られた最小(大)点との距離の函数関係の推定の一方法である。一方、(b-3)は、どちらかといへば性質のわるい函数から、いくつかの標準的な計算しやすいものとえらび、これらを標準問題を解くはやく、信頼性等によりアルゴリズムを評価しようとするものである。今日、上べかかれている test function 等を附録に示す。

問題

本稿では、N変数実函数

$$f(\mathbf{x}) \quad \mathbf{x} = (x_1, x_2, \dots, x_N) \in \mathbb{R}^N$$

に最大または最小値を与える点、—最大(小)点、 $\hat{f}(\mathbf{x})$ を求めるアルゴリズムを考える。特別の場合を除き、変数には制約条件をつけず、また、函数は唯一つの極大(小)点をもつものとする。

函数が唯一つの極大(小)を持つことを仮定することには、多分、異論があろう。しかし、この条件をのぞいても、確定的に最大(小)点に到達できるような手法は何一つない。ある

。実用的には、乱数を使って多くの点における函数の値を調べるとか、出発点をかえて、同じ手法を繰り返す以外に方法がないのである。

また、場合によつては、さらに、目的函数の微分可能性、2回連続微分可能性、あるいは目的函数が定符号の2次形式であることを仮定しなければならない。しかし、同時に、これらの前提条件を除くことが一つの努力目標ともなるわけだから、上の問題設定もいわば標準的な定式化として掲げておくわけである。

变数の数(N)についていえば、1变数の場合と多变数の場合では取扱いを異にするが、こゝでは多变数の場合を中心に、1变数の場合には必要に応じて補足して行くことにする。また多变数の場合の説明の際には、主に2变数の場合の言葉——山、谷、尾根、峠、鞍部等を流用する。

以下、各節で順を追い、最大(小)点を求めるアルゴリズムを述べる。よく知られてゐるようだに、最大点を求める問題と最小点を求める問題は、目的関数の符号を変えるだけで互に变换できるので、以下では、一々ことわらずに、いずれか一方を取りあげて説明する。

I 勾配法 (Gradient Method)

これは、最適化の手法として、最も基本的なもので、最も広く使われているものである。それだけに、いろいろな変形があり、いろいろな名称で呼ばれている。中でも、最も原始的な形のものが、次の Primitive Gradient Method である。

1 Primitive Gradient Method

この方法は、大ざっぱにいえば、ある点 $x^{(0)}$ をわりて函数の値が大きくなる方向を求め、この方向に向ってへんらか進み、その点を $x^{(1)}$ とし、又、その点を中心として函数の値が大きくなる方向を求めるという手順を繰返すものである。

目的函数がデータ一覧用可能という作業仮説下で、二項までまとめて考えてみよう。

$$(1) \quad f(x) \cong f(x^{(0)}) + \text{grad } f(x^{(0)}) \cdot (x - x^{(0)})$$

すなわち、点 $x^{(0)}$ からあまりはなれていない点に於ける函数の値は、大体、右辺の値で近似されると言えるわけである。

そこで、考えてる点 $x^{(0)}$ を中心とする半径 $r (> 0)$ の(超)球を考え、この球面上での函数の値が最も大きくなる点を、

上の近似によつて求めれば、これが

$$(2) \quad \bar{x} = x^{(0)} + \delta \cdot (\text{grad } f(x^{(0)}))^T / \| \text{grad } f(x^{(0)}) \|$$

であることがわかる。すなわち、この点 $x^{(0)}$ の近傍では、
 $\text{grad } f$ の方向が、目的函数の値が最も大きくなる方向なのである。そこで、まずこの方向に向つて進むことが考えられる。（これが gradient 法の名の由来である。）別のいへすすれば、函数が（ $N+1$ 次元空間で）作る曲面に、接（超）平面をあてがい、この平面上での最大傾斜線に沿つて登つて行こうと“うもの”である。

この過程は、次の漸化式で示される。


$$(3) \quad x^{(m+1)} = x^{(m)} + h_m (\text{grad } f(x^{(m)}))^T$$

ここで、問題となることがいくつある。

第一の問題は、初期点 $x^{(0)}$ のえらび方である。これは普通、経験的に最適な点があるだろうと思われる点がえらばれるが、山が二つ以上ある場合には、えらび方如何によつて、高い山へのぼらずに、低い山へのぼってしまう可能性があるので、全過程を 1 回だけではなく、他の初期点についてもくりかえしてみる必要がある。（図 I-1）

第二の問題は、各变数の単位のとり方である。一般に、各变数が共通の単位玉も、物理量であるわけではないし、また、仮にそうだとしても、同じ測定単位で測定されなければな

低い山

図 I - 1 $x^{(0)}$ のそらひ方

ぬという論理的な必然性もない。そこで、変数ごとに、違う測定単位を用いたとしても、上と同様の議論が成立する苦である。しかし、これ本、旧座標で、 $x^{(0)}$ を中心とする球を中心とすることのかわりに、稍円体をとったにすぎない。元来、 $x^{(0)}$ を中心とする球をとること自体、特別に理由があるわけではなく、たゞ便宜上そうしたにすぎない。極端な話が、 $x^{(0)}$ を中心とする‘超’立方体をとって、その面上での最大値をとっても、一向に差支えないはずである。

‘立方体’をとるところも、微分等式すら都合上具合がわかるから、一度 $x^{(0)}$ を中心とする一般的な位置にある稍円体

$$(4) \quad (\mathbf{x} - \mathbf{x}^{(0)})^T \mathbf{B} (\mathbf{x} - \mathbf{x}^{(0)}) = \delta^2$$

$\hat{x} > 10$,

$B : N \times N$ 正定符号行列

を考え、この面上で函数の値が最も大きくなる点を、やはり、テーラー展開の第2項までをとった近似によつて求めてみれば、


$$(5) \quad \hat{x} = x^{(0)} + \frac{\delta B^{-1}(\text{grad } f(x^{(0)}))^T}{(\text{grad } f(x^{(0)}))^T B^{-1}(\text{grad } f(x^{(0)}))}$$

が得られる。この式について、 $B = I$ ($I : N \times N$ 単位行列) とおけば、(2)と同じものが得られるが、一般($B \neq I$)には異なる。従つて、この方向をたどつても、接平面の最大傾斜線を登ることにはならない。 $x^{(0)}$ と(5)式を直すぶ方向によつて、primitive gradient method → 一般的な漸化式を書ければ次のようになる。

$$(6) \quad x^{(m+1)} = x^{(m)} + h_m B^{-1}(\text{grad } f(x^{(m)}))^T$$

ところで、ここで、どのよしな精度体(すなはち B)をとつたらよいかという問題が生ずるが、これは後で論ずることにしよう。

次に、次の問題は、「ステップ・サイズ」 h_m の選定である。 h_m が小さすぎれば、 $\{x^{(m)}\}$ の動きがにぶくなり、 \hat{x} になかなか近づかれない。大きすぎれば振動を起して、かえつて具合が悪い(図工-乙)。

図 I - 2 h_m のえらび方

それでは、 h_m をどのよきな値に選んだらよいか？まず、どのような条件で下で $x^{(m)}$ が \hat{x}^* に収束するのか？途中まで行った計算によって得られた、目的函数 $h(x)$ に関する情報を生かして、 h_m が収束のための条件をみたすようにすることはできないか？さらに収束の速度をはやめることはできないか？という問題がでてくる。

h_m のえらび方にに関する理論的な研究は Crockett-Chernoff ^{<4>} によって行われている。Crockett Chernoff の研究の主要な部分を以下に述べる。

Crockett-Chernoff の研究

目的函数 $f(\mathbf{x})$ はテーラー展開により、次のように近似で
まるものとする。

$$(7) \quad f(\mathbf{x}) = f(\check{\mathbf{x}}) + \frac{1}{2} (\mathbf{x} - \check{\mathbf{x}})^T H (\mathbf{x} - \check{\mathbf{x}}) + O(\|\mathbf{x} - \check{\mathbf{x}}\|^3)$$

ここで、

$\check{\mathbf{x}}$: $f(\mathbf{x})$ の最小点,

$$H = \left\{ \frac{\partial^2 f}{\partial x_i \partial x_j} \right\}_{x=\check{x}} : \text{正定符号対称行列}$$

$$i, j = 1, 2, \dots, N$$

である。このとき、 $\check{\mathbf{x}}$ を求めると、次の漸化式によつて与
えられる点列を用いる。

$$(8) \quad \mathbf{x}^{(m+1)} = \mathbf{x}^{(m)} + h_m \mathcal{J}(\mathbf{x}^{(m)})$$

ここで、

$$\mathcal{J}(\mathbf{x}) = -B^{-1}g(\mathbf{x})$$

$$g(\mathbf{x}) = (\text{grad } f(\mathbf{x}))^T$$

$B : N \times N$ 正定符号対称行列

である。

いま、

$$(9) \quad \mathcal{T}^{(m)} = \mathcal{J}(\mathbf{x}^{(m)})$$

$$\mathbf{E}^{(m)} = \mathbf{x}^{(m)} - \check{\mathbf{x}}$$

とおくと、次の関係式が成立する（証明略）。

$$(10) \quad \begin{aligned} \mathbf{e}^{(m+1)} &= (\mathbf{I} - h_m \mathbf{B}^{-1} \mathbf{H}) \mathbf{e}^{(m)} + o(\mathbf{e}^{(m)}) \\ \mathcal{D}^{(m)} &= -\mathbf{B}^{-1} \mathbf{H} \mathbf{e}^{(m)} + o(\mathbf{e}^{(m)}) \\ \mathcal{D}^{(m+1)} &= (\mathbf{I} - h_m \mathbf{B}^{-1} \mathbf{H}) \mathcal{D}^{(m)} + o(\mathbf{e}^{(m)}) \end{aligned}$$

また、 $\mathbf{B}^{-1} \mathbf{H}$ は正定符号対称行列であるから、この行列の固有値はすべて正であり、これに属する固有ベクトルは線形独立である。これを

$$\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_N > 0$$

$$\mu_1, \mu_2, \dots, \mu_N$$

としよう。このとき、 $\mathbf{e}^{(m)}$ および $\mathcal{D}^{(m)}$ をこの固有ベクトルの線形結合として次のように書こう。

$$(11) \quad \begin{aligned} \mathbf{e}^{(m)} &= k_1^{(m)} \mu_1 + k_2^{(m)} \mu_2 + \cdots + k_N^{(m)} \mu_N \\ \mathcal{D}^{(m)} &= \bar{k}_1^{(m)} \mu_1 + \bar{k}_2^{(m)} \mu_2 + \cdots + \bar{k}_N^{(m)} \mu_N \end{aligned}$$

$\mathbf{e}^{(m)}$ および $\mathcal{D}^{(m)}$ に関する上にあげた関係式 (10) によつて、これら係数 $k_i^{(m)}$ および $\bar{k}_i^{(m)}$ に関する次の関係式が導かれること。

$$(12) \quad \begin{aligned} k_i^{(m+1)} &= (1 - h_m \lambda_i) k_i^{(m)} + o(\mathbf{e}^{(m)}) \\ \bar{k}_i^{(m)} &= -\lambda_i k_i^{(m)} + o(\mathbf{e}^{(m)}) \\ \bar{k}_i^{(m+1)} &= (1 - h_m \lambda_i) \bar{k}_i^{(m)} + o(\mathbf{e}^{(m)}) \end{aligned}$$

$\mathbf{e}^{(m)}$ や $\mathcal{D}^{(m)}$ がゼロに収束すれば、 $\mathbf{x}^{(m)}$ がゼロになります。そして、 $\mathbf{e}^{(m)}$ や $\mathcal{D}^{(m)}$ がゼロに収束するためには、 $k_i^{(m)}$ や $\bar{k}_i^{(m)}$ がゼロに収束すればよい。上の式からあきらかのように、

$\hat{r}_i^{(m)}$ や $\bar{r}_i^{(m)}$ がゼロに収束するためには、

$$(13) \quad |1 - h_m \lambda_i| < 1 \quad i = 1, \dots, N$$

であればよい。さらに、(13) が成立するためには、

$$(14) \quad 0 < h_m < \frac{\bar{\lambda}}{\lambda_1 + \lambda_N}$$

であればよい。

また、このとき、 m が十分大きくなると $|1 - h_m \lambda_i|$ の小さいものに向する \hat{r}_i や \bar{r}_i は早くにゼロに近づいてしまうから、

$$(15) \quad \mathcal{J}^{(m)} = \bar{r}_N^{(m)} \mu_N$$

$$(16) \quad \mathcal{J}^{(m+1)} \approx (1 - h_m \lambda_N) \mathcal{J}^{(m)} \quad m : 大$$

が成立する。

理論的には、以上のようなことがわかるわけだが、実際の問題を解く場合には、最初から H や λ_i や μ_i がわかるわけでも、容易に推定できるわけでもない。したがって、上の条件を満たすように h_m を定める方法が明確になつたわけではない。そこで、Crockett-Chernoff は以上の理論をふまえて h_m のえらび方の指針を示している。

(1) h_m は m の増加とともに次第に大きくなる。

(2) $\mathcal{J}^{(m)}$ と $\mathcal{J}^{(m+1)}$ の方向が著しく異なるときには、 h_m の増加を予びかえる — あるいは h_m を小さく

する。

$$(八) \quad d^{(m+1)} = \rho d^{(m)}, \quad \rho: \text{正の定数で} 1 < \rho \leq 1 + \text{小さな値}$$

が成立する場合には

$$h_{m+1} = \frac{h_m}{1-\rho}$$

とする。

これらの指針の中で、(1) は点列が山の長い尾根に沿って登る場合の加速的な効果をねらっており、(2) は $x^{(m)}$ が $\nabla f(x)$ まわりで振動に入るのを防いでいる。(い) では、 m が大なるとき、(16) が成立するとこから、

$$\begin{aligned} \rho &\approx 1 - h_m \lambda_N \\ \Rightarrow h_{m+1} &= \frac{h_m}{1-\rho} \approx \frac{1}{\lambda_N} \end{aligned}$$

従って、 $d^{(m+1)}$ が大目に減少することが期待できる。

実際の問題を計算機にかけて解こうとする場合には、まだいろいろな問題点がある。例えば、漸化式

$$x^{(m+1)} = x^{(m)} + h_m B^{-1} (\text{grad } f(x^{(m)}))^T$$

に於いて $\text{grad } f(x)$ が解析的な形で得られるとはまれである。従って、何等かの形で数値微分に類することを行わな

ければならない。しかし、各点で非常に精密な数値微分を行っても、全体としての効率があがるわけではなくことはあきらかであろう。そのようなわけで、実際のアルゴリズムとしては、かなり大胆に簡略化を行った方がいいらしい点で異合が多い。

次に、実際の計算の場合によく使われている pattern search とよばれるアルゴリズムを紹介しておく。これは、ある意味で、Crockett-Chernoff の指針を多くの点で具体化したものともいうことができる。

Pattern Search

この方法は大ざっぱにいふと、「パターンの中心」と「ベース・ポイント」とよばれる二つの点列を交互に定義して、山頂に向うのであるが、このとき、ベース・ポイントはパターンの中心の附近で函数の値が大きな点に、パターンの中心はこのベース・ポイントを結ぶ直線上に立つのである。

簡単のため、2変数の場合について手順の詳細を説明しておく。3変数以上の場合も同様である。





图 I-3 Pattern Search

- (i) 2つの数 $\delta_1, \delta_2 > 0$ を適当に定め、これをステップ・サイズとよぶ。
- (ii) 適当な1点をえらび、これで、最初のパターンの中心 $C^{(1)}$ と最初のベース・ポイント $b^{(1)}$ を兼ねるものとする。
- (iii) パターン決定 いま、 m 番目のパターンの中心が $C^{(m)} = (C_1^{(m)}, C_2^{(m)})$ にあるとき、3点 $C^{(m)} = (C_1^{(m)}, C_2^{(m)}), (C_1^{(m)} + \delta_1, C_2^{(m)}), (C_1^{(m)} - \delta_1, C_2^{(m)})$ において目的函数の値を求め、その値が最も大きい点を
- $$C^{(m+1)} = (C_1^{(m+1)}, C_2^{(m+1)})$$
- と書こう。さらに、3点 $C^{(m+1)} = (C_1^{(m+1)}, C_2^{(m+1)}), (C_1^{(m+1)}, C_2^{(m+1)} + \delta_2), (C_1^{(m+1)}, C_2^{(m+1)} - \delta_2)$ において目的函数の値を求め、その値が最も大きい点を新しいベース・ポイント $b^{(m+1)}$ とする。パターンの中心から、新しいベース・ポイントを定めるこの手順をパターン決定とよぶ。

実際にパターン決定を行なうのに、一度に3点を比較するのも面倒であるから、例えば、



$$(C_1^{(m)}, C_2^{(m)}) \leq (C_1^{(m)} + \hat{\sigma}_1, C_2^{(m)})$$

によける函数の値を比較し、 $(C_1^{(m)}, C_2^{(m)})$ の二つの値

が大きいと見て $(C_1^{(m)} - \hat{\sigma}_1, C_2^{(m)})$ を調べることに

しよう。 $(C_1^{(m)}, C_2^{(m)})$ の附近で、函数が‘谷’にな

っている場合には、こうすると多少遠まわりになる

ことがあるが、多くの場合に計算量をへらすことに

なる。

(IV) パターン移動 新しいパターンの中心点のよう


にして定められる。(図 I-5)

$$(i) f(\mathbf{b}^{(m)} + \alpha(\mathbf{b}^{(m+1)} - \mathbf{b}^{(m)})) > f(\mathbf{b}^{(m+1)}) \text{ かつ},$$

$$\mathbf{c}^{(m+1)} = \mathbf{b}^{(m)} + \alpha(\mathbf{b}^{(m+1)} - \mathbf{b}^{(m)})$$

$$(ii) f(\mathbf{b}^{(m)} + \alpha(\mathbf{b}^{(m+1)} - \mathbf{b}^{(m)})) \leq f(\mathbf{b}^{(m+1)}) \text{ かつ},$$

$$\mathbf{c}^{(m+1)} = \mathbf{b}^{(m+1)}$$



こゝに、 α は1より大きな定数であり、通常、2.0にとられる。 α が1.0より大きいことは、図I-5からもわかるように、尾根にそって進むとき、次第に‘歩み’が大きくなるという加速的な効果をもたらす。このようにして、新しいパターンの中心を求める手順をパターン移動といふ。

(V) ステップ・サイズの縮小と探索の停止 最初に与えられたパターンの中心とベース・ポイントから、パターン決定とパターン移動を交互にくりかえして、点列 $\{c^{(m)}\}$ および $\{b^{(m)}\}$ を決定していくが、パターン決定のとき、新しいベース・ポイントが $b^{(m+1)} = c^{(m)}$ となつたら、これをすて、ステップ・サイズをたとえば $\delta_1/3$, $\delta_2/2$ に縮小して探索を再開する。このようにして、探索をつづけるうちにはステップ・サイズがあらかじめ定めておいた値よりも小さくなつたら探索をやめるのである。

3 Optimum Gradient Method

h_m を立てるもとの方
法は、上に述べた方法で方向
が立まつたら、その方向を向
いた、 $x^{(m)}$ を始点とする半直
線上で目的函数の値が最も大
きくなる点をとり、次々近似
点 $x^{(m+1)}$ とすることである。

この方法は、Optimum Gradient Method とよばれるもの

で、Cauchy <1> が1847年に、最初に勾配法を提唱したの
もこの形である。Cauchy は、天体の軌道を計算するとい
う应用上の目的から、方程式の一般的な解法としてこの方法
を考へてゐるが、文献<1>はごく短いもので、收束の証明等
はされていない。(勿論、Cauchy が考へたのは $B = I$ の
場合である。)

その後も、一部の数学者達によつて变分問題の解法等に、
この方法が应用された。特に、Канторович <12> 等は
Hilbert空間で定義された函数方程式の解法として、この方
法に関する理論を發展せつゝいるが、工学上の应用としては
、1944年にCurry <2> が应用上のデータはなく、むしろ、




図 I - 6

収束の証明等に力が注がれているが、この方法の広い応用の可能性を示唆する一方、座標のとり方の問題等、それ以後他の人々によって研究されたいくつかの問題点が指摘されていることは注目に値しよう。

こゝでもまた、目的函数 $f(x)$ を、 $x^{(m)}$ を中心としてテーラー展開し、2階偏微係数を含む項までをとって、函数を近似してみよう。

$$\begin{aligned} f(x) \approx & f(x^{(m)}) + \text{grad } f(x^{(m)}) \cdot (x - x^{(m)}) \\ & + \frac{1}{2} (x - x^{(m)})^T H(x^{(m)}) (x - x^{(m)}) \end{aligned}$$

ここで、

$$H(x^{(m)}) = \left\{ \frac{\partial^2 f}{\partial x_i \partial x_j} \right\} \quad i, j = 1, \dots, N$$

この近似にもとづいて、 $x^{(m)}$ を通る直線

$$x = x^{(m)} + \xi P$$

上で、函数が最大値をとる点を求めれば、($P^T H(x^{(m)})P < 0$ のとき)

$$x = x^{(m)} - \frac{\text{grad } f(x^{(m)}) \cdot P}{P^T H(x^{(m)}) \cdot P} \cdot P$$

となる。従って、この近似を用いることにはすれば、optimum gradient method の手順は次の漸化式であらわされる。

$$\boldsymbol{x}^{(m+1)} = \boldsymbol{x}^{(m)} - \frac{\text{grad } f(\boldsymbol{x}^{(m)}) \cdot \boldsymbol{P}}{\boldsymbol{P}^T H(\boldsymbol{x}^{(m)}) \cdot \boldsymbol{P}} \cdot \boldsymbol{P}$$

$$\boldsymbol{P} = B^{-1} (\text{grad } f(\boldsymbol{x}^{(m)}))$$

なお、ここで直線 $\boldsymbol{x}^{(m)} + \lambda \boldsymbol{P}$ が $\boldsymbol{x}^{(m+1)}$ で $f(\boldsymbol{x})$ の等高線と接することにも注意しておく必要がある。

こゝでもまた、いくつかの問題があらわれる。

第1の問題は、 $\boldsymbol{x}^{(m)}$ を 1 回の計算するたびに、 $H(\boldsymbol{x}^{(m)})$ と $\text{grad } f(\boldsymbol{x}^{(m)})$ を計算しなければならないことである。

もちろん、これが解析的な方法でできて、しかも、簡単な場合には問題はない。しかし

これは稀である。そこで、一々数値的に求めることになればこれは面倒である。

まず、

$$\text{grad } f(\boldsymbol{x}^{(m)}) = \left(\frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \dots, \frac{\partial f}{\partial x_N} \right) \Big|_{\boldsymbol{x}=\boldsymbol{x}^{(m)}}$$

であるが、この近似値を計算するには、たとえば、

$$\left. \frac{\partial f}{\partial x_1} \right|_{\boldsymbol{x}=\boldsymbol{x}^{(m)}} \approx \frac{1}{\Delta x_1} [f(x_1^{(m)}, x_2^{(m)}, \dots, x_N^{(m)}) - f(x_1^{(m)}, x_2^{(m)}, \dots, x_N^{(m)})]$$




図 I-7

と、いうような近似を行なわなければならぬ。このような簡単な方法でも、 $\text{grad } f$ を計算するたびに、目的函数 $f(x)$ の値を $N+1$ 回計算（又は測定）しなければならないので、 N が大きいときには大変なことである。

primitive gradient method の場合の、この点に対する一つの解決法が pattern search であったわけだが、optimum gradient method を使ふうとするなら、 $\text{grad } f(x^{(m)})$ の計算はいすれにせよ求めかれない。

次に、

$$H(x^{(m)}) = \left\{ \frac{\partial^2 f}{\partial x_i \partial x_j} \right\} \quad i, j = 1, \dots, N$$

であるが、これを、数値的に近似しようとするれば更に面倒なことになる。そこで、一つの逃げ道として考えられることは、直線 $x = x^{(m)} + \xi P$ 上に於ける函数 $f(x)$ の最大点を直接数値的な方法で求めることがある。この方が、optimum gradient method 本来の形であるし、計算も簡単になることが少くないからである。

なかでも、この計算が解析的な方法で行われれば話は簡単であるが、そうでない場合には、一般的にいって、1変数函数の最大点を数値的に求めることが問題になる。これにも、いろいろな方法が工夫されているが、こゝでは、次のような方法があることにふれておくだけにとどめよう。

- (a) 差分五点とし、符号の変化をしきべる。
- (b) 2次関数をあてはめ(数値的に)、その上で差分五計算(解析的に)する。
- (c) 黄金分割法

実際, optimum gradient method の場合に $H(x^{(m)})$ が直接計算されることは非常に少ない。これは、せっかく, H を行列の形で求めてみても $P^T H P$ というスカラーラー量にして使うのでは計算に無駄が多い。行列の形で H を求めるのなら、むしろ, 次節で述べる Newton 法でも使った方がよいということがあるからである。

する問題は, primitive gradient method の場合と一部共通の問題であるが, 最大方向を求める際に用いた積用体

$$(x - x^{(m)})^T B (x - x^{(m)}) = \tilde{\sigma}^2$$

のえらび方が問題である。目的函数の形が, 定符号行列によって与えられる2次形式である場合には, 図 I-8 からも明らかのように,

$$B = H$$

とすれば, 一回で, 最大点にさしつかずに到達することができる。この場合, H を一度に求めてしまわなくてよ




図 I-8

近似の進行とともに B を変化させ，次第に H に近づけることを考慮される。

$$B^1, B^2, \dots \rightarrow H$$

また，目的函数が近似的に次形式で表わされる場合でも， B を変化させ，

$$B^{(m)} = H(x^{(m)})$$

とすれば，収束とはやめることができてゐる。しかし，これらの取扱いは，ましく，次節で述べる Newton 法の方が適当である。

II Newton 法

目的函数を点 $x^{(m)}$ を中心としてテーラー展開し、2階偏微係数を含む項までとめて近似しよう。

$$\begin{aligned} f(x) \approx f(x^{(m)}) + \text{grad}f(x^{(m)}) \cdot (x - x^{(m)}) \\ + \frac{1}{2} (x - x^{(m)})^T H(x^{(m)}) (x - x^{(m)}) \end{aligned}$$

このとき、 $H(x^{(m)})$ が正定符号であれば、右辺の函数に最小値を与える点は

$$x = x^{(m)} - H^{-1}(x^{(m)}) \cdot (\text{grad}f(x^{(m)}))^T$$

で与えられる。従って、上の近似の精度が十分高く、しかも、 H の正定符号性が確かめられれば、目的函数の最小点もこの点の近くにあることが予想される。

そこで、これら条件の下で

$$x^{(m+1)} = x^{(m)} - H^{-1}(x^{(m)}) (\text{grad}f(x^{(m)}))^T$$

という漸化式の作る点列によって、最小点への近似をすゝめて行くことができる。 \therefore 本方法を Newton 法と言う。(図 II-1)

この方法が、方程式の根を求める際に用いられる、いわゆる、Newton の近似法と同じものであることは明らかである。実際、連立方程式

$$(\text{grad}f(x))^T = 0$$

互解くのに、Newton の近似法を適用してみれば、上と同じ漸化式が得られる。

また、optimum gradient method について、

$$B^{(m)} = H(x^{(m)})$$

とおいても、上と同じ漸化式が得られる。

この Newton の方法には、勾配法の場合とは異なる新しい問題がでてくる。

その問題は $H(x^{(m)})$ の正定符号性である。これが保証され




図 II-2

図 II-1

んでいなければ、 H^{-1} を計算できるかどうかも……といし
、仮に出来たとしても、 $x^{(m)}$ が鞍点上に停止してしまつたり
、振動を起してしまう可能性がでてくる。しかし、図 II-2
からも明らかのように、1つの最小点をもつ函数であっても
、 H が負定符号になつたり、函数の作る曲面が鞍点をもち、
 H について、正負いずれの定符号性もいなくなることが起
りうるのである。

このような問題に取り組んでいるものとして、Goldfeld,
Quandt, Trotter の考え方がある<24>。彼等の提唱する方法
は、目的函数が作る曲面の地形を調べて、適宜 Newton 法や
、これを修正したものを使うものだが、以下にその理論の主
要な点を述べる。

Goldfeld, Quandt, Trotter の研究

目的函数 $f(x)$ は2次函数とする。すなわち、点のを中心
としてテーラー展開すれば

$$f(x) = f(a) + (\text{grad } f(a))(x-a) + \frac{1}{2}(x-a)^T H(x-a)$$

と書ける。こゝに、 H は一定の(対称)行列であるが、 H の
定符号性等は仮定しないでおく。

いま、

$$H - \alpha I, \quad I : \text{単位行列}$$

という行列を考えると、 α を十分大きくすれば負定符号の行列になる。実際、 H の固有値（ H の対称性により実数）を

$$\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_N$$

とし、これに属する固有ベクトルを

$$u_1, u_2, \dots, u_N \quad \|u_i\| = 1 \quad i=1, \dots, N$$

とすれば、明らかに、 $H - \alpha I$ の固有値、固有ベクトルは

$$\lambda_1 - \alpha \geq \lambda_2 - \alpha \geq \cdots \geq \lambda_N - \alpha$$

$$u_1, u_2, \dots, u_N$$

となるから、 α を $\alpha > \lambda_1$ とすれば固有値はすべて負になる。以後、 α はこのようにとる。

次に、点 a を中心に次のようない近傍を考える

$$B_\alpha = \{x \mid \|x - a\| \leq \|(H - \alpha I)^{-1}(\text{grad } f(a))^T\|\}$$


この球は $\alpha \in (\lambda_1, \infty)$ の範囲、すなわち、 $H - \alpha I$ が負定符号になる範囲では α の増加とともに小さくなる。(狭義の減少)

そこで、 B_α 内に属する函数 $f(x)$ の最大点を調べてみると次のようない結果が得られる。

(1) $\text{grad } f(a) \neq 0$ の場合

(i) H が負定符号でないと $(\alpha > \lambda_1 \geq 0)$

$$x_c = a - (H - \alpha I)^{-1}(\text{grad } f(a))^T$$





(口) H が負定符号のとき

(i) $\alpha < 0$ なら,

$$\mathbf{x}_0 = \mathbf{a} - H^{-1}(\text{grad } f(\mathbf{a}))^T$$

(ii) $\alpha > 0$ なら,

$$\mathbf{x}_0 = \mathbf{a} - (H - \alpha I)^{-1}(\text{grad } f(\mathbf{a}))^T$$




(2°) $\text{grad } f(\mathbf{a}) = 0$ の場合

この場合には B_α は点のみになってしまい、 a を中心として任意の半径 $\alpha > 0$ の球を考えれば、この球内での最大点は


(i) $\lambda_1 > 0$ なら (a は鞍点または最小点)

$$\mathbf{x}_0 = \mathbf{a} + \lambda_1 \mathbf{u}_1$$



(ii) $\lambda_1 \leq 0$ なら

$$\mathbf{x}_0 = \mathbf{a}$$



以上の結果をもとに, Goldfeld, Quandt, Trotter は実際
に計算するためのアルゴリズムとして次のような方法を提案
している。(目的函数は2次函数とは限らない)

(a) $\|\text{grad } f(\mathbf{x}^{(m)})\| \gg 0$ の場合

$$\mathbf{x} = \mathbf{a} + R \|\text{grad } f(\mathbf{x}^{(m)})\|$$

R : 正のパラメター

とおき, 点列 $\{\mathbf{x}^{(m)}\}$ を次の漸化式で定義する。こゝに, λ_1 は
 $H(\mathbf{x}^{(m)}) = \left\{ \frac{\partial^2 f}{\partial x_i \partial x_j} \right\}_{x=\mathbf{x}^{(m)}}$ の最大固有値である。

$\alpha \geq 0$ のとき、

$$\mathbf{x}^{(m+1)} = \mathbf{x}^{(m)} - (\mathbf{H}(\mathbf{x}^{(m)}) - \alpha \mathbf{I})^{-1} \cdot (\text{grad } f(\mathbf{x}^{(m)}))^T$$

$\alpha < 0$ のとき、

$$\mathbf{x}^{(m+1)} = \mathbf{x}^{(m)} - \mathbf{H}^{-1}(\mathbf{x}^{(m)}) \cdot (\text{grad } f(\mathbf{x}^{(m)}))^T$$

すなわち、目的函数の曲面をしらべて、その点の附近で函数が凸である場合 ($\alpha < 0$) には、通常の Newton 法と、これがいえない場合には、目的函数の $\mathbf{H}(\mathbf{x}^{(m)})$ を $\mathbf{H}(\mathbf{x}^{(m)}) - \alpha \mathbf{I}$ という行列に書きかえず Newton 法を適用するわけである。

(b) $\|\text{grad } f(\mathbf{x}^{(m)})\| \approx 0$ の場合

$\mathbf{H}(\mathbf{x}^{(m)})$ の固有値

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$$

を調べ

$\lambda_1 < 0$ のとき

$\mathbf{H}(\mathbf{x}^{(m)})$ は負定符号であるから $\mathbf{x}^{(m)}$ はほぼ最大点に到達している。

$\lambda_1 \geq 0$ のとき

$\mathbf{x}^{(m)}$ は鞍点である。そして

$$\mathbf{x}^{(m+1)} = \mathbf{x}^{(m)} + \gamma \mathbf{u}_1$$

とする。ここで \mathbf{u}_1 は λ_1 に属する固有ベクトル、 γ は正のパラメーターである。

次の問題は、 $H(x^{(m)})$ とその逆行列 $H^{-1}(x^{(m)})$ の計算である。これらは普通、可成りの計算量に至るので、できれば“避けたい”。

このためにも、いろいろなアイデアが出されている。たとえば、 $H(x^{(m)})$ と $H(x^{(m)})^{-1}$ を一度計算したら、しばらくの間 ($m+1, m+2, \dots, m+\ell$) は、近似的に、これらをそのまま使うとするものである。また、次に述べる quasi-Newton 法の考え方もある。

Quasi Newton 法

これは、通常の Newton 法で、一挙に H や H^{-1} を計算しようとせず、適当な定符号行列 $G^{(0)}$ から始めて、計算の途中で得た、目的函数に関する情報を使って、次第に H^{-1} に近づく行列の列

$$G^{(0)}, G^{(1)}, \dots, G^{(m)}, \dots \rightarrow H^{-1}$$

を作ろうとするものである。

特に、目的函数の形が本当に定符号行列によって与えられる二次曲面である場合には、 H^{-1} が x に依存せず、一意的に定まっているから論ははつきりしている。また、見方をかえると、optimum gradient method の所で述べた、積円体を用いた行列 B を変化させて行く方法と、この方法は、実は、

同じものになる。である。

もちろん、こゝでも、点列 $x^{(m)}$ の収束性の問題がでてくる。しかし、この場合には、理論上、有限回で H^{-1} に合致するような行列の列 $\{G^{(m)}\}$ を作るアルゴリズムが知られていく。だから、これに従えば、計算が誤差をともなわぬかぎり、 $x^{(m)}$ も有限回で最大点や最小点に合致することになる。

前にも述べたが、目的函数が定符号行列によって与えられる二次曲面である場合に、 $x^{(m)}$ が有限回で最大点や最小点に合致する性質があるとき、アルゴリズムは ‘exact’ あるいは ‘finite quadratically convergent’ といわれる。この性質は、実用工も大事なのでアルゴリズムを設計する上で重要視されている。

Quasi-Newton 法とよばれるものにも、いくつかの形があるようだがその詳細は参考文献<25> にゆすり、こゝでは、Davidon<6> によつて提案され、Fletcher-Powell<46> によつて整理されたものをあけておこう。

Fletcher Powell の方法

この方法は次のよきな手順によって点列 $x^{(m)}$ を与え、目的函数 $f(x)$ の最小点 x^* に近づこうとするものである。

1) $G^{(0)}$ = 任意の正定符号対称行列

2) $x^{(0)}$ = 初期点、任意

3) $\alpha^{(m)} = -G^{(m)} g_j^{(m)}$ とする。 $j > 1$

$$g_j^{(m)} = (\text{grad } f(x^{(m)}))^T$$

4) $x^{(m)}$ を始点とし、 $\delta^{(m)}$ 方向を向いた半直線上で、目的函数の値が最も小さくなる点を求める。すなわち、

$$f(x^{(m)} + \lambda \delta^{(m)}) = \min_{\lambda} f(x^{(m)} + \lambda \delta^{(m)})$$

を計算し、

$$\sigma^{(m)} = \alpha^{(m)} \delta^{(m)}$$

とおく。


$$5) \quad x^{(m+1)} = x^{(m)} + \sigma^{(m)}$$

$$6) \quad G^{(m+1)} = G^{(m)} + A^{(m)} + B^{(m)}$$

$$A^{(m)} = \sigma^{(m)} \cdot \sigma^{(m)T} / (\sigma^{(m)T} y^{(m)})$$

$$B^{(m)} = - (G^{(m)} \sigma^{(m)}) (G^{(m)T} G^{(m)}) / (y^{(m)T} G^{(m)} y^{(m)})$$

$$y^{(m)} = g^{(m+1)} - g^{(m)}$$



このような手順で行列 $G^{(m)}$ を定めて行くと

$$G^N = H^{-1} \quad (N: \text{変数の数})$$

となることが証明されてゐるが、これは文献<16>にゆずる。また、この方法は Hilbert 空間でも全く同様に使えること、線形部分空間での最小点を求めるのに、多少の修正をすれば使えることが最近 Horwitz - Sarachik によって示されてゐる<33>。

III One at a time method

さて、かねて名前ではあるが、この方法の最も原始的な形は次のようなものである。

目的函数

$$f(\mathbf{x}) = f(x_1, \dots, x_N)$$

の最小点に近づく点列を作るのに、これまで述べて来た方法のように、grad f とか、 $H = \left\{ \frac{\partial^2 H}{\partial x_i \partial x_j} \right\}$ のような、局所的な情報は使わず、 N 個の単位ベクトル

$$\mathbf{P}_1, \dots, \mathbf{P}_N$$

をあらかじめ定めておき、走っている点から、これらの方向に沿って、順々に最小点を求めて行くのである。

すなはち

$$f(\mathbf{x}^{(m)}) = \min_{\xi} f(\mathbf{x}^{(m-1,N)} + \xi \mathbf{P}_1)$$


$$f(\mathbf{x}^{(m,2)}) = \min_{\xi} f(\mathbf{x}^{(m,1)} + \xi \mathbf{P}_2)$$

…




$$f(\mathbf{x}^{(m,N)}) = \min_{\xi} f(\mathbf{x}^{(m,N-1)} + \xi \mathbf{P}_N)$$

という形で点列を定義していくのである。

ベクトル $\mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_N$ の立ち位置としては、座標軸方向に立つのが最も初等的なやり方である。実用上この方法で成功した例は少くないが、理論上は、収束性の点でかなり問題がある。このことは、図 III-1 (3 次元の場合) と図 III



四 五 - 4



四 三 - 2

-2 (いまく行かない場合) を対比してみればよいのである。一般的にいって、図III-2にあるよろな、鋭い鞍線があるときには、具合がわるい。目的函数が2次形式で書ける場合にも図III-3のような細長い椭円体の等高線があらわれるのは、点列 $x^{(m)}$ はなかなか最小点に近づかない。デジタル・計算機で計算を行う場合には、量子化がなされるのですます具合がわるくなることになる。




図 III-3

また、この方法は連立方程式を解く Gauss-Seidel 法に対応しているので、点列を定義する漸化式が書ければ、Seidel 過程の収束性吟味の方法を適用することができる。しかし、参考書では、漸化式そのものの改良法はあまり得られない。

一方、図III-1(b) のように、等高線の形によっては、有限回で最小点に到達してしまう。図III-1(a) の椭円と図III-2(b) の椭円は、実は、同じ形のものなので、このことは

$$P_1, \dots, P_N$$

の立ち方か、収束性に大きく影響することを示してある。

目的函数が、2次形式である場合には、 P_1, \dots, P_N をどのようにとればよいかという点については次のことが知ら

れている。

共役ベクトル

正定符号対称行列 H を $\frac{1}{2}$ とする。2つのベクトル p, q のこの
 $\boxed{N \times N}$ 行列に関する2次形式

$$P^T H Q$$

がゼロになるとき、ベクトル p および q は互に共役であるといわれる。

いま、 $n (\leq N)$ 個の互に共役なベクトル

$$P_1, P_2, \dots, P_n$$

をとる、

$$f(x^{(1)}) = \min_{\xi} f(x^{(0)} + \xi P_1)$$

$$f(x^{(2)}) = \min_{\xi} f(x^{(1)} + \xi P_2)$$

...

$$f(x^{(n)}) = \min_{\xi} f(x^{(n-1)} + \xi P_n)$$

以上手順により $x^{(n)}$ を求めると、 $x^{(n)}$ は、 P_1, \dots, P_n の張る部分空間内での、2次形式

$$x^T H x$$

の最小点にある。

そこで、何等かの方法によって変数の数($=N$)だけの線形
独立で互に共役なベクトル

$$P_1, \dots, P_N$$

が得られれば、 N 回の iteration にて最小点に到達する
とがである。

しかし、共役であるかいかを決定するのは、目的函数自
身の性質であるから、結局のところ、計算の過程でこのよ
うなベクトルをさがして行かなければならぬ。すなむち、最
初、線形独立なベクトルの組

$$[P_1 | P_2 | \dots | P_N]$$

から出発して、線形独立であると同時に共役なベクトルの組

$$[P_1^{(M)} | P_2^{(M)} | \dots | P_N^{(M)}]$$

が得られるような過程を考えればよい。

このような過程として提案されているのがいくつかある
。 $\langle 3 \rangle, \langle 14 \rangle, \langle 25 \rangle, \langle 34 \rangle, \langle 30 \rangle$ また、上のベクトルの組をマトリ
ックスとしてとらえれば Quasi-Newton 法とも関係がつく。

こでは、Zangwill $\langle 30 \rangle$ の手順をあげておく。

Zangwill の方法

この方法は、任意の相異なる N 次のベクトルから出発して、最小化の過程をくりかえしながら、互に共役なベクトルを作るもので、直接目的函数の偏微係数を求める手順とは含まれていない。目的函数が一次形式である場合を想定して作られた方法だが、その他の場合にも使えないことはない。(もちろんこの場合には最小値に有限回のステップで到達できるとは保証しない。) 手順は次の通りである。

(i) 座標軸方向の単位ベクトルを

$$\mathbf{e}_n, n=1, \dots, N$$

とする。

(ii) オルスティップ⁰

$$\text{初期点 } \mathbf{x}^{(0)}$$

$$N = n \text{ 相異なる単位ベクトル } \mathbf{p}_n, n=1, \dots, N$$

をとる。

$$f(\mathbf{x}^{(0)} + \lambda^{(0)} \mathbf{p}_n) = \min_{\lambda} f(\mathbf{x}^{(0)} + \lambda \mathbf{p}_n)$$

をと $\lambda_n^{(0)}$ を求めよ。

$$\mathbf{x}_{n+1}^{(0)} = \mathbf{x}_n^{(0)} + \lambda_n^{(0)} \mathbf{p}_n^{(1)}$$

とする。

$t = 1, k = 1$ としてオルスティップ⁰へ

(iii) キルステップ

キルステップへ入るときには

$x_{N+1}^{(k-1)}, p_n^{(k)}$ ($n=1, \dots, n$), t
が与えられている。

$$(1) f(x_{N+1}^{k-1} + \alpha C_t) = \min_{\mu} f(x_{N+1}^{k-1} + \mu C_t)$$

なる。 α を求める。

$$1 \leq t < n \text{ のとき } t \rightarrow t+1$$

$$t = n \Rightarrow t = n$$

とする。

(a) $\alpha \neq 0$ の場合

$$x_0^k = x_{N+1}^{k-1} + \alpha C_t$$

とする。(a)へ

(b) $\alpha = 0$ の場合

(b)の最後へもどる。(b)の手順がN回くりか

えされれば x_{N+1}^{k-1} は最小点

(a) $n=1, \dots, N$ について

$$f(x_{n-1}^k + \lambda_n^k p_n^k) = \min_{\mu} f(x_{n-1}^k + \mu p_n^k)$$

なる λ_n^k を求め、

$$x_n^k = x_{n-1}^k + \lambda_n^k p_n^k$$

とする。また、

$$p_{N+1}^k = (x_n^k - x_{N+1}^{k-1}) / \|x_n^k - x_{N+1}^{k-1}\|$$

とする。

$$f(\mathbf{x}_N^k + \lambda_{N+1}^k \mathbf{P}_{N+1}^k) = \min_{\mu} f(\mathbf{x}_N^k + \mu \mathbf{P}_{N+1}^k)$$

なる λ_{N+1}^k を求め


$$\mathbf{x}_{N+1}^k = \mathbf{x}_N^k + \lambda_{N+1}^k \mathbf{P}_{N+1}^k$$

とし、

$$\mathbf{P}_n^{k+1} = \mathbf{P}_{n+1}^k, \quad n=1, \dots, N$$

とおり、 $k+1$ ステップへ

図 III-4 に $N=2$ の場合の手順を等高線図上に示す。



STOP

Simplex 法

これは、線形計画の問題を解くのに用いられる有名なシンプロレックス法とは別のものである。非線形の連立方程式を解く際に用いられる secant method <5> に対応するものである。

ここでいうシンプロレックス法は、 N 変数 x_1, x_2, \dots, x_N のつくる N 次元空間の適当な位置に、適当な大きさの N 次元シンプロレックス（一次独立な $N+1$ 個の点を頂点とする图形）をとり、その各頂点における目的函数の値を比較して、これが最も小さい値をとる頂点を、函数がもとと大きな値をとる新しい点に入れかえて、新しいシンプロレックスを作り。この手順をくりかえして、シンプロレックスを‘山の頂上’に近づけるのである。

シンプロレックス法の手順は次の通りである。

- (i) 変数 x の N 次元空間の適当な位置に、適当な大きさの N 次元のシンプロレックス

$$S^{(0)} = \{ x_1^{(0)}, \dots, x_{N+1}^{(0)} \}$$

をとる。

- (ii) 第 m 番目のシンプロレックス

$$S^{(m)} = \{ x_1^{(m)}, \dots, x_{N+1}^{(m)} \}$$

の各頂点における函数の値 $f(x_1^{(m)}), f(x_2^{(m)}), \dots, f(x_{N+1}^{(m)})$

を比較して次の3つのものを定める。

(1) 函数の値が最も大きい頂点, $x_h^{(m)}$

$$y_h^{(m)} \equiv f(x_h^{(m)}) = \max_i \{f(x_i^{(m)})\}_{i=1}^{N+1}$$

(2) 函数の値が最も小さい頂点,

$$y_\ell^{(m)} \equiv f(x_\ell^{(m)}) = \min_i \{f(x_i^{(m)})\}_{i=1}^{N+1}$$

(3) 函数の値が2番目に小さい頂点,

$$y_s^{(m)} \equiv f(x_s^{(m)}) = \min_{i \neq \ell} \{f(x_i^{(m)})\}_{i=1}^{N+1}$$

(iii) $x_\ell^{(m)}$ を除く N 個の頂点の中心 $x_m^{(m)}$ を求める。

$$x_m^{(m)} = \frac{1}{N} \sum_{i \neq \ell} x_i^{(m)}$$


(iv) $x_\ell^{(m)}$ と $x_m^{(m)}$ を直すぶ直線上, $x_m^{(m)}$ とは反対側に点

$$x_\alpha^{(m)} = (1 + \alpha) x_m^{(m)} - \alpha x_\ell^{(m)}, \quad \alpha > 0$$

とする。こゝで, α はパラメタ (適当にえらぶ) であるが,

$$\alpha = \frac{\overline{x_m^{(m)} x_\ell^{(m)}}}{\overline{x_m^{(m)} x_\ell^{(m)}}}$$


という関係をみだしている。



この点における函数の値を

$$y_\alpha^{(m)} = f(x_\alpha^{(m)})$$

とする。この $y_\alpha^{(m)}$ を (ii) で求めた $y_e^{(m)}, y_s^{(m)}, y_h^{(m)}$ と比較する
と次の 4 つの場合がある。



これらの場合に応じて、シンプレックス $S^{(m)}$ を次のように改める。

$$(i) \quad y_h^{(m)} < y_\alpha^{(m)}$$

この場合には、函数は $x_\alpha^{(m)}$ 方向に向って非常に急な
登り坂になつているものと考えられる。そこで、この
線をさらに延長して、点

$$x_\gamma^{(m)} = \gamma x_\alpha^{(m)} + (1-\gamma)x_m^{(m)}, \quad \gamma > 1$$

を定める。 $\gamma > 1$ は、 γ はパラメター（適当に定める）
であるが、

$$\gamma = \overline{x_m^{(m)} x_\gamma^{(m)}} / \overline{x_m^{(m)} x_\alpha^{(m)}}$$

という関係を満たしている。

点 $x_\gamma^{(m)}$ における函数の値を計算し、

(i) $f(x_\gamma^{(m)}) > y_h^{(m)}$ の場合には $x_\gamma^{(m)}$ をすべて $x_\gamma^{(m)}$
とし新しいシンプレックス $S^{(m+1)}$ をつくる。

(b) $f(x_\beta^{(m)}) \leq y_s^{(m)}$ の場合には、 $x_\beta^{(m)}$ をすてゝ、 $x_\alpha^{(m)}$ をとり、新しいシンプロックス $S^{(m+1)}$ を作る。

(c) $y_s^{(m)} \leq y_\alpha^{(m)} \leq y_h^{(m)}$
この場合には、 $x_\alpha^{(m)}$ をすてゝ $x_\alpha^{(m)}$ をとり、新しいシンプロックス $S^{(m+1)}$ を作る。

(d) $y_e^{(m)} \leq y_\alpha^{(m)} < y_s^{(m)}$
この場合には2点、 $x_\alpha^{(m)}$ 、 $x_m^{(m)}$ の間に次のようないくつかの点、 $x_\beta^{(m)}$ をとる。

$$x_\beta^{(m)} = \beta x_\alpha^{(m)} + (1-\beta)x_m^{(m)}$$

 ここで、 β はパラメタ-(適当に之を定める)であるが、

$$\beta = \overline{x_m^{(m)} x_\beta^{(m)}} / \overline{x_\alpha^{(m)} x_m^{(m)}}$$

という関係をみたしてある。

したがつて、 $x_\beta^{(m)}$ における函数の値を計算し、

(a) $f(x_\beta^{(m)}) > y_s^{(m)}$ の場合には、 $x_\beta^{(m)}$ をすてゝ $x_\beta^{(m)}$ をとり、新しいシンプロックス $S^{(m+1)}$ を作る。

(b) $f(x_\beta^{(m)}) \leq y_s^{(m)}$ の場合には、シンプロックスが大きすぎるとき考慮されるので、 $x_h^{(m)}$ を中心としてシンプロックスを次のように縮小す

3. すなはち

$$x_i^{(m+1)} = (x_h^{(m)} + x_i^{(m)}) / 2$$

$$x_h^{(m+1)} = x_h^{(m)}$$

を頂点とするシンプレックスを新しいシンプレックス $S^{(m+1)}$ とする。

$$(=) \quad y_\alpha^{(m)} < y_\ell^{(m)}$$

この場合には、2点 $x_\ell^{(m)}$, $x_m^{(m)}$ の間に次の
ような点 $x_{\beta'}^{(m)}$ をとる。

$$x_{\beta'}^{(m)} = \beta' x_\ell^{(m)} + (1 - \beta') x_m^{(m)} \quad 0 < \beta' < 1$$


ここで、 β' はパラメーター（適当にとらぶ）であるが

$$\beta' = \frac{\overline{x_m^{(m)} x_{\beta'}^{(m)}}}{\overline{x_m^{(m)} x_\ell^{(m)}}}$$

という関係をみだしてある。

点 $x_{\beta'}^{(m)}$ における函数の値を計算し、

(a) $f(x_{\beta'}^{(m)}) > y_s$ の場合には、 $x_\ell^{(m)}$ を
捨てて、 $x_{\beta'}^{(m)}$ をとる、新しいシンプレックス
を作ること。



(a) $f(x_j^{(m)}) \leq y_j^{(m)}$ の場合には (a), (b) で

のべた手順をよってシンプソン法を
縮小する。

(b) $S^{(m+1)}$ が得られたら、各頂点における函数の値を計算
し、そのバラツキ

$$\frac{1}{N} \sum_{i=1}^{N+1} (f(x_i^{(m+1)}) - \frac{1}{N} \sum_{j=1}^{N+1} f(x_j^{(m+1)}))^2$$

を調べ、これが、予め定められているある定数より小
くなっていたら計算を停止する。

以上の手順は、計算の都合上とりきめた部分が多いが、本
質的な部分は、要するに、最初の所でもふれたように、シンプ
ソン法を、函数の値が大きくなる方向に動かして行くこ
とである。たゞ、注意すべきことは、シンプソン法が計算
の途中で縮退しないようにすることである。(上の手順では
、その心配がないようになっている。)

附録 I Test Functions


最適化手法の評価のため、標準問題として使われた Test function のうち主なものと次に列挙する。

(1) Parabolic Valley, Rosenbrock's curved valley <7>

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$$

最小点および最小値 $f(1, 1) = 0$

等高線図



(2) Helical valley <16>

$$f(x_1, x_2, x_3) = 100(x_3 - 10\theta)^2 + (x_2 - 1)^2 + x_3^2$$

$$x_1 = r \cos 2\pi\theta$$

$$x_2 = r \sin 2\pi\theta$$

(3) Function of 4 variables by Powell <11>


$$f(x_1, x_2, x_3, x_4) = (x_1 + 10x_2)^2 + 5(x_3 - x_4)^2 + (x_2 - 2x_3)^4 + 10(x_1 - x_4)^4$$

(4) 2 dimensional exponential function <21>

$$f(x_1, x_2) = \sum_a [(e^{-ax_1} - e^{-ax_2}) - (e^{-a} - e^{-10a})]^2$$

$$a = 0.1 (0.1) 1$$

最小点および最小値: $f(1, 10) = 0$



(5) 3-dimensional exponential function <21>


$$f(x_1, x_2, x_3) = \sum_a [(e^{-x_1 a} - e^{-x_2 a}) - x_3(e^{-a} - e^{10a})]^2$$

最小点および最小値 $a = 0.1 (0.1)^{11}$

$$f(1, 10, 1) = 0$$

(6) 2-dimensional trigonometric function <21>

$$f(x_1, x_2) = \sum_{i=1}^2 [E_i - \sum_{j=1}^2 (A_{ij} \sin x_j + B_{ij} \cos x_j)]^2$$

(7) N-dimensional trigonometric functions <21>

$$f(x_1, \dots, x_N) = \sum_{i=1}^N [E_i - \sum_{j=1}^N (A_{ij} \sin x_j + B_{ij} \cos x_j)]^2$$

($N = 5, 10, 20$)

(8) Functions with saddle points (Crater function) <24>

$$(i) f(x_1, x_2) = e^{-x_1 - x_2} (2x_1^2 + 3x_2^2)$$


最大点および最大値 $f(0, 1) = 3e^{-1}$

$$f(0, -1) = 3e^{-1}$$

鞍点およびその値 $f(1, 0) = 2e^{-1}$

$$f(-1, 0) = 2e^{-1}$$

最小点および最小値 $f(0, 0) = 0$



$$(ii) f(x_1, \dots, x_5) = e^{-\sum_{i=1}^5 x_i^2} (3.0x_1^2 + 2.0x_2^2 + 3.5x_3^2 + 4.0x_4^2 + 2.7x_5^2)$$

附 錄 II 參 考 文 獻

- 1> Cauchy,A.L. < Méthode Générale pour la Résolution des Systèmes d'Équations Simultanée, C.R.Read Sci.,Paris,25,536-538,1847
- 2> Curry,H.B. < The Method of Steepest Descent for Non-Linear Minimization Problems > Quarterly of Applied Mathematics Vol.2,pp258-260 ,1944
- 3> Hestenes,M.R. and Stiefel,E. < Method of Conjugate Gradients for Solving Linear Systems > Journal of the Research of the National Bureau of Standards, Vol.49, No.6 pp409-436,1952
- 4> Crockett,J.B. and Chernoff, H. < Gradient Methods of Maximization> Pacific Journal of Mathematics,Vol.5,pp 33-50,1955
- 5> Wolfe,P. < The Secant Method for Simultaneous Nonlinear Equations > Communication of the ACM, Vol.2,pp 12-13,1959
- 6> Davidon,W.C.< Variable Metric Method for Minimization > Research and Development Rep.ANL-5990, Atomic Energy Commission 1959
- 7> Rosenbrock, H. H. < An Automatic Method for finding the Greatest or Least Value of a Function > The Computer Journal, Vol.3, pp 175-184, 1960-1
- 8> Martin,D.W. and Tee,G.J. < Iterative Methods for Linear Equations with Symmetric Positive Definite Matrix > The Computer Journal Vol.4,pp 242-254 ,1961
- 9> Spang,III,H.A. < A Review of Minimization Techniques for Nonlinear Functions > SIAM Review, Vol.4,pp343-365, 1962

- <10> Bellman,R.E. and Dreyfus, S.E. < Applied Dynamic Programming >, Princeton Univ. Press, 1962
- <11> Powell,M.J.D.< An Iterative Method for finding Stationary Values of a Function of several Variables > The Computer Journal, Vol.5, pp 147-151, 1962
- <12> Kantrovich ,L.V. and Akilov,G.P. < Functional Analysis in Normed Spaces >, Pergamon Press, 1964
- <13> Wilde,D.J. <Optimal Seeking Methods> Prentice Hall, 1964
- <14> Fletcher ,R. and Reeves,C.M. < Function Minimization by Conjugate Gradients > The Computer Journal, Vol.7, pp 149-154, 1964
- <15> Powell,M.J.D. < An Efficient Method for finding the Minimum of a Function of Several Variables without calculating Derivatives. > The Computer Journal, Vol.7, pp 155-162 1964
- <16> Fletcher ,R. and Powell, M.J.D. < A Rapidly Convergent Descent Method for Minimization > The Computer Journal, Vol.6 pp163-168, 1964
- <17> Fletcher,R. < Function Minimization without evaluating Derivatives --- a Review > The Computer Journal, Vol.8, No.1 pp33-41, 1965
- <18> Nelder, J.A. and Mead,R. < A Simplex Method for Function Minimization > The Computer Journal, Vol. 7, No.4, pp 308-312 1965
- <19> Faure,F. et Huard, P. <Resolution de Programmes Mathematiques a Fonction Non Lineare par la Method du Gradient Reduit > Revue Française de Recherche Operationnelle, N°36, pp167-206, 1965

- Box,M.J. < A New Method of Constrained Optimization and a
<20> Comparison with other Methods > The Computer Journal,
Vol. 8, No.1, pp 42-52,1965
- Box,M.J. < A Comparison of Several Current Optimization Methods,
<21> and the use of Transformations in Constrained problems >
- 柳井浩 < 最大最小の探索の方法 >, 数学セミナー
<22> 1965,(4),(6), 1966 (1),(2)
- Greenstadt,J.L. < A Ricocheting Gradient Method for Nonlinear
<23> Optimization > SIAM, Appl.Math., Vol.14, No3, pp429-445,
1966
- Goldfeld,S.M. and Quandt,R.E. & Trotter,H.F. < Maximization
<24> by Quadratic Hill Climbing > Econometrica, Vol.34, No.3
pp 541-551,1966
- Broyden,C.G. < Quasi-Newton Method and their Application to
<25> Function Minimization > Mathematics of Computation, Vol.
21, pp 368-381 1966
- Greenstadt,J. < On the Relative Efficiencies of Gradient Methods >
<26> Mathematics of Computation, Vol.21, pp 360-367,1966
- Burrows,J.W. < Maximization of a Second-Degree Polynomial
<27> on the Unit Sphere > Mathematics of Computation, Vol.20,
No.95, pp441-444,1966
- Wilde,D.J. and Avriel,M. < Optimal Search for a Maximum with
<28> Sequences of Simultaneous Function Evaluations > Management
Science, Vol.12, No.9, pp722-731, 1966
- Lavi,A. and Vogl,T.P. (ed) < Recent Advances in Optimization
<29> Technique >, John Wiley & Sons, Inc., 1966

- Zangwill,W.I. < Minimizing a Function without Calculating
 <30> Derivatives > The Computer Journal, Vol.10, No.3, pp 293-296,
 1967
- Stewart III,G.W. < A Modification of Davidon's Minimization
 <31> Method to Accept Difference Approximation of Derivatives >
 Journal of the ACM, Vol.14, pp72-83 ,1967
- 柳井 浩 < 最適値問題とその定式化 > オペレーションズ・
 <32> リサーチ, 1968, (1)
- Horwitz,L.B. and Sarachik,P.E. < Davidon's Method in Hilbert
 <33> Space > SIAM J. Appl.Math. Vol.16,no.4, pp 676-695, 1968
- Zeleznik,F.J. < Quasi-Newton Method for Nonlinear Equations >
 <34> Journal of the ACM, Vol.15,No.2, pp 265-271,1968
- Colville,A.R. < A Comparative Study on Nonlinear Programming
 <35> Codes > IBM New York Scientific Center Report No.320-2949,
 1968
- Wilde,D.J. and Avriel,M. < Golden Block Search for the Maximum
 <36> of Unimodal Functions > Management Science, Vol.14, No.5,
 pp 307-319,1968
- Duffin,R.J. and Karlovitz,L.A. < Formulation of Linear Programs
 <37> in Analysis I: Approximation Theory >, SIAM J.Appl.Math.
 Vol.16, No.4, July, 1968
- Luenberger,D.G. < Convex Programming and Duality in Normed
 <38> Space > IEEE Transaction on Systems Science and Cybernetics,
 Vol.SSC-4, No.2, 1968
- <39>