

# 多變量函數之最小值

last modified November 27, 2012

許多的應用問題，如最大概似函數的參數估計，最後都要計算多變量函數的最小值。<sup>1</sup>之前的單元也介紹過單一變數函數的最小值演算法，本單元將之擴展到多個變數，看看 MATLAB 如何解決這些問題，並介紹著名的 Newton-Raphson method 及簡潔的 Steepest Descent method。

## 本章將學到關於程式設計

MATLAB 演算法指令的使用、一般演算法的程式寫作、立體圖形的繪製技巧及 MATLAB 圖形工具的使用。

〈本章關於 MATLAB 的指令與語法〉

指令: meshgrid, mesh, surf, contour, colorbar, fminsearch, optimset, fprintf

---

<sup>1</sup>最大值與最小值的計算被視為同一個問題，其差別只是目標函數的正負號而已。

# 1 背景介紹

多變量函數的最小值的問題表示如下：

$$\min_{\mathbf{x}} f(\mathbf{x}) \quad (1)$$

其中函數  $f(\mathbf{x}) : R^n \rightarrow R$ , 假設為可做二次微分的連續函數, 並且為變數  $\mathbf{x}$  的非線性函數。譬如圖1是兩個變量的函數圖, 有一個最小值在底部的凹陷處。




圖 1: 兩個變量的函數圖

計算  $f(\mathbf{x})$  最小值的必要條件為

$$\nabla f(\mathbf{x}) = \begin{bmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_n} \end{bmatrix} = \mathbf{0} \quad (2)$$

即令梯度向量為零向量。由於  $f(\mathbf{x})$  的非線性關係，上式為一組非線性的聯立方程式，通常推導不出所謂的 closed-form solution。因此必須藉助演算法的迭代方式逐步找到最小值。例如

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{d}_k \quad k = 0, 1, 2, \dots$$

在選擇一個適當的初始值  $\mathbf{x}_0$  後，透過適當的「方向」( $\mathbf{d}_k$ ) 調整，一步步的逼近函數的最小值。其中最負盛名的「方向」選擇為 Newton-Raphson method, 其法則如下：

$$\mathbf{d}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k) \quad (3)$$

其中  $n \times 1$  的向量  $\nabla f(\mathbf{x}_k)$  稱為梯度向量 (Gradient Vector), 而  $\nabla^2 f(\mathbf{x})$  為一  $n \times n$  的對稱性矩陣，一般稱為 Hessian matrix, 在此並假設其反矩陣存在，其定義如下

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_2} & \dots & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_n} \end{bmatrix} \quad (4)$$

由於 Hessian matrix 牽涉到非線性函數的二次微分，在某些情況下並不容易推導或因反矩陣的計算上有困難 (或不存在)，因此出現了許多「改良」型的方式，試圖避開這些問題。其中最簡單，卻也非常有效的一個替代方案：朝梯度向量的反方向前進，即

$$\mathbf{d}_k = -\nabla f(\mathbf{x}) \quad (5)$$

一般稱為 Steepest Descent direction。由於比較簡單，通常也做為一開始嘗試的選擇。不過當函數的本身或最小值附近呈現較平滑的趨勢時，這個方式將出現收斂緩慢的情況。

## 2 練習

在進行以迭代法計算多變量函數最小值之前，如果能將函數圖形畫出來，將有助於起始值的選擇，選取適當的迭代方向。以下將先練習三維函數圖形的繪製。

範例 1. 繪製下列函數的圖形

$$f(x, y) = xe^{-x^2-y^2}$$

繪製立體函數圖形的觀念如平面圖的作法：

1. 首先必須先訂出  $X - Y$  平面的範圍與格子 (grids), 其 MATLAB 指令如下

```
[X,Y]=meshgrid(變數 X 的範圍, 變數 Y 的範圍)
```

矩陣  $X$  與  $Y$  代表  $X - Y$  平面上格子點上的  $X$  與  $Y$  座標。關於 `meshgrid` 的詳細用法請自行 `help meshgrid`。圖 2 是執行 `[X,Y]=meshgrid(-2:2,-1:3)` 的結果。如果  $X$  與  $Y$  的座標範圍一樣，指令中只需輸入一組範圍即可。

```
X =
    -2    -1     0     1     2
    -2    -1     0     1     2
    -2    -1     0     1     2
    -2    -1     0     1     2
    -2    -1     0     1     2
Y =
    -1    -1    -1    -1    -1
     0     0     0     0     0
     1     1     1     1     1
     2     2     2     2     2
     3     3     3     3     3
```

圖 2: meshgrid 的概念

2. 利用  $X$  與  $Y$  計算函數在平面上每一個格子點上的函數值  $Z$ 。在 `help meshgrid` 裡面可以看到相關的用法。圖 3 展示以 `meshgrid` 的概念繪製函數  $z =$

$f(x, y) = xe^{-x^2-y^2}$  的立體圖。圖中因為格子間隔較寬的原因, 所以可以清楚的看出  $X - Y$  平面的格子點狀及其對應的  $Z$  值高度。指令如

```
Z = X.*exp(-X.^2 - Y.^2);  
mesh(X, Y, Z)
```

3. 不妨試著從 `meshgrid` 指令調整格子的寬度, 看看效果如何。
4. 繪製函數圖。立體函數圖的指令很多, 如 `mesh`, `surf`, `contour`(等高線圖) 等。
5. 利用 Matlab 的圖形旋轉功能 (在圖形工具列選擇「Rotate 3D」), 以滑鼠適度的旋轉圖形的角度, 找出一個容易觀察極值的位置, 並藉此調整繪圖的範圍。




圖 3: `meshgrid` 的概念與立體圖

函數圖如圖 4 所示。圖 4(b) 的等高線圖特別加了一條顏色帶 (colorbar)，表示高度或大小，在圖形的工作列上可以找到這個功能，或是在 contour 指令後面加上 colorbar 的指令。另外，等高線圖是個平面圖，有時會因為 XY 軸的不均衡，造成視覺上的落差，譬如，應該看起來是正圓形的圖，卻變成橢圓。譬如圖 4，這是個 XY 軸 ( $x_1$  vs.  $x_2$ ) 對稱的圖形，為彰顯此對稱性，可以在圖形產生後加上以下的指令

axis square




圖 4: (a) 函數的立體圖 (mesh)(b) 等高線圖 (contour)

製作立體圖也可以採迴圈的方式選取  $X - Y$  平面上如棋盤式的  $(x, y)$  座標，配合匿名函數，逐點計算函數值，如下列程式所示。其中第 7 行是函數值的計算，並將結果放入預先設定記憶體的  $Z$  矩陣中。此處列向量代表  $Y$  的方向，行向量代表  $X$  的方向，配合指令 mesh 才能呈現正確的函數圖形。

```

f = @(x,y) x * exp(-x^2 - y^2);
x=-3:0.1:3;
y=-4:0.1:4;
Z=zeros(length(y),length(x));
for i=1:length(x)
    for j=1:length(y)
        Z(j,i)=f(x(i),y(j));
    end
end
mesh(x,y,Z)
xlabel('X'),ylabel('Y')

```

範例 2. 繪製下列函數的圖形

$$f(x_1, x_2) = (x_1 - 2)^4 + (x_1 - 2)^2 x_2^2 + (x_2 + 1)^2 \quad (6)$$

圖形如圖 1 所示。習者可以自行翻轉圖形找到最佳觀察的角度，也可以多利用其他繪製立體圖的指令（譬如，`contour`），看看是否有更理想的視覺效果。使用 `contour` 指令時，可以加入第四個參數，決定多少條等高線，如

```
contour(X, Y, Z, 100)
```

多變量函數的圖形僅限於兩個變量，因此能在實務上發揮的機會不多。不過計算多變量的函數的極值，倒是不受限制。只是當變數愈多時，所花的時間愈長，也愈容易陷入區域極值。以下先舉例說明 MATLAB 現成的處理多變量函數極值的指令，之後再說明如何自己撰寫演算法。

範例 3. 利用 MATLAB 計算多變量函數的最小值的指令 `fminsearch` 計算

$$\min_{x_1, x_2} (x_1 - 2)^4 + (x_1 - 2)^2 x_2^2 + (x_2 + 1)^2$$

MATLAB 計算多變量函數最小值的方式，依問題分為兩類：限制式 (constrained) 及非限制式 (unconstrained)。一般而言限制式比較麻煩，也通常以非限制式做為基礎，容後討論。這裡先討論 MATLAB 處理非限制式函數的指令 `fminsearch`，方式如

```
f = @(x) (x(1) - 2)^4 + (x(1) - 2)^2 * x(2)^2 + (x(2) + 1)^2;  
[x, fval] = fminsearch(f, [0, 0]);
```

MATLAB 處理函數的計算多半使用匿名函數的方式，複雜些的函數甚至可以使用副程式 (function)。多變量函數的匿名函數，其變數以向量方式表示。`fminsearch` 的第二個參數是初始值的設定。當函數的「長相」崎嶇不平時，不同初始值的設定可能導致不同的答案與計算的時間長短，特別當變數愈多時。所以使用者必須小心使用這個指令，每次都試著給不同的初始值，檢視結果，就知道這個函數容不容易對付了。

除了初始值的選擇可能影響結果外，設定 `fminsearch` 搜尋極值的停止條件有時候也很關鍵。下列程式展示 MATLAB 提供使用者介入指令功能的設定。

```
opts=optimset('fminsearch');  
opts.Display='iter';  
opts.MaxFunEvals=8000;  
opts.MaxIter=8000;  
opts.TolFun=1e-6;  
opts.TolX=1e-6;  
f = @(x) (x(1) - 2)^4 + (x(1) - 2)^2 * x(2)^2 + (x(2) + 1)^2;  
[x, fval] = fminsearch(f, [0, 0], opts);
```

演算法涉及停止條件的設定，MATLAB 利用 `optimset` 指令給使用者一些自主的空間，依據函數的特性或工作需求，訂定演算法停止點。MATLAB 訂定的停止條件可以借第一行的結果得知。`opts` 是一個結構型變數，從命令視窗輸入 `opts` 便可以知道有多少可以設定的參數。比較關鍵的幾個參數如第 2 到 6 行。

`Display` 選項改為 `iter`，可以在執行時看到每個迴圈的部份結果，這方面提供使用者了解這個函數的特性，特別是接近極值時的平滑程度，藉以設定下面幾個參



數。MaxFunEvals 決定做最大的函數計算次數,有些函數非常複雜龐大,計算時間長,因時間或成本考量,必須限制計算次數,不管是否接近極值,都要喊停。MATLAB 預設為 200\*變數個數。使用者有必要觀察演算法停止在哪個條件上,才能適度的修改參數值。MaxIter 則是演算法的迴圈數,預設值也是 200\*變數個數。TolFun 是函數值的變化量,當函數值在演算的過程中幾乎不再改變,這是還停的時機,MATLAB 預設這個變化量為 1e-4,<sup>2</sup>這裡下修為 1e-6。另外從變數變化的程度也可以喊停,TolX 預設為 1e-4,這裡下修為 1e-6。

不當的設定或完全不理會 MATLAB 的預設值,有時會得到不正確的結果,通常是還沒到達極值便停止計算。使用者必須謹慎小心。MATLAB 在 optimization toolbox 裡提供了另一個指令, fminuncon, 同樣用來計算非限制式多變量函數的極值。這個指令用了不同的演算法,並允許使用者提供函數的偏微分函數,採用梯度向量在演算法裡。

此外,限制式極值的問題也很常見。在 MATLAB 官網的 file exchange 裡,可以下載到從 fminsearch 改編的 fminsearchcon 指令,用來處理限制式極小值問題,非常出色。網址: <http://www.mathworks.com/matlabcentral/fileexchange/8277-fminsearchbnd-fminsearchcon>。以下的範例說明它的使用。另一個在 optimization toolbox 處理限制式多變量函數的極值是 fmincon。

---

範例 4. 利用 John D'Errico 為 fminsearch 撰寫的延伸版, fminsearchcon, 計算下列限制式多變量函數的最小值。

$$\min_{x_1, x_2 \in \Omega} (x_1 - 2)^4 + (x_1 - 2)^2 x_2^2 + (x_2 + 1)^2$$

其中  $\Omega$  為

1.  $\Omega = \{x_1, x_2 \in R \mid x_1 \geq 0, x_2 \geq 0\}$
2.  $\Omega = \{x_1, x_2 \in R \mid x_1 \leq 1, x_2 \leq 2\}$
3.  $\Omega = \{x_1, x_2 \in R \mid 0 \leq x_1 \leq 1, 0 \leq x_2 \leq 2\}$

---

<sup>2</sup>在 MATLAB ,1e-4 代表  $10^{-4}$ 。

$$4. \Omega = \{x_1, x_2 \in R \mid 0 \leq x_1 \leq \infty, -\infty \leq x_2 \leq 2\}$$

$$5. \Omega = \{x_1, x_2 \in R \mid x_1 + x_2 \leq 0.9\}$$

$$6. \Omega = \{x_1, x_2 \in R \mid 1.5 \leq x_1 + x_2 \leq 2\}$$

$$7. \Omega = \{x_1, x_2 \in R \mid \sqrt{x_1^2 + x_2^2} \leq 1\}$$

$$8. \Omega = \{x_1, x_2 \in R \mid \sqrt{x_1^2 + x_2^2} \leq 1, x_1 x_2 \geq 0\}$$

$$9. \Omega = \{x_1, x_2 \in R \mid x_1 + x_2 = 0.9\}$$

---

限制式條件就是對未知變數的限制，在實際應用上經常碰到。譬如變數值必須為正，或是代表機率值必須在 0 與 1 之間。這個範例蒐集了一些典型的限制式條件，也是 `fminsearchcon` 指令要解決的。習者宜打開 `fminsearchcon` 程式，好好研究如何置入這些限制式條件在指令中。典型的指令如

```
[x, fval]=fminsearchcon(fun, x0, LB, UB, A, b, nonlcon, options);
```

其中 `fun` 及 `x0` 代表目標函數與初始值，`LB, UB` 是向量，代表變數的下限與上限，即  $LB \leq \mathbf{x} \leq UB$ ，`A, b` 代表變數的線性不等式，即  $A\mathbf{x} \leq b$ ，`A` 矩陣，`b` 為向量。`nonlcon` 代表變數的非線性關係函數  $C(\mathbf{x}) \leq 0$ ，譬如  $\sqrt{x_1^2 + x_2^2} \leq 1$ ，MATLAB 寫成 `@(x)norm(x) - 1`，或是先寫成  $g = \text{@}(x)\text{norm}(x) - 1$ ，再以 `g` 代表 `nonlcon`。當非線性限制條件超過一個時， $C(\mathbf{x})$  代表一個向量函數，如範例中的兩個非線性限制條件，寫成  $g = \text{@}(x)[\text{norm}(x) - 1; -x(1) * x(2)]$

MATLAB 的 `optimization toolbox` 裡面的 `fmincon`，在參數的安排與設定上有點不同，習者應參照使用說明的指示，計算本範例，看看與 `fminsearchcon` 有何不同。下一個範例將 `fminsearchcon` 應用在實際的問題，函數複雜許多，變數也比較多，很有挑戰性。

---

範例 5. 圖 5 是 1000 筆資料的直方圖。假設這些資料來自兩個  $\beta$  分配的組合，即分配函數為

$$f(x|\Omega) = \pi_1\beta(x|a_1, b_1) + \pi_2\beta(x|a_2, b_2)$$

其中  $\Omega = \{\pi_1, \pi_2, a_1, b_1, a_2, b_2\}$ ,  $\pi_1 + \pi_2 = 1$ 。請試著採取最大概似參數估計法 (MLE) 來估計參數  $\Omega$ 。

寫出概似函數

$$L(\Omega) = \sum_{i=1}^{1000} \ln(\pi_1\beta(x_i|a_1, b_1) + \pi_2\beta(x_i|a_2, b_2))$$

問題變成

$$\max_{\Omega=\{\pi_1, \pi_2, a_1, b_1, a_2, b_2\}, \pi_1+\pi_2=1, \pi_1>0, \pi_2>0} L(\Omega)$$

這是一個限制式的極值問題，限制條件在兩個參數  $\pi_1 + \pi_2 = 1$  及  $\pi_1, \pi_2 > 0$ 。這個限制式可以被修改為  $0 < \pi_1 < 1$ 。其中  $\pi_2$  直接以  $1 - \pi_1$  取代，變數減為 5 個。程式片段如下 (假設樣本資料已經存放在變數  $x$ )

```

opts=optimset('fminsearch');
opts.Display='iter';
opts.MaxFunEvals=8000;
opts.MaxIter=8000;
opts.TolFun=1e-6;
opts.TolX=1e-6;
initial=[0.5 1 10 5 5];
LB=[0 0 0 0 0];
UB=[1 Inf Inf Inf Inf];
L = @(p) - sum(log(p(1) * betapdf(x,p(2),p(3)) + (1 - p(1)) *
betapdf(x,p(4),p(5))));
[mle, fval] = fminsearchcon(L, initial, LB, UB, [], [], [], opts);

```

結果如何呢？習者不妨自己模擬資料，看看估計的結果與真實參數值相差多少。也可以試著將直方圖與估計出來的函數圖畫在一起，看看估計的結果是否貼近資料的分佈。




圖 5: 來自混合  $\beta$  分配樣本的直方圖

---

範例 6. 推導函數 (6) 的梯度向量  $\nabla f(\mathbf{x})$  及 *Hessian Matrix*  $\nabla^2 f(\mathbf{x})$

---

以演算法計算極值，通常需要紙筆推導到一定的程度，才進行程式的寫作，不是忙亂的一陣砍殺或是坐在哪兒發呆不知從何下手。因此在真正應用演算法之前，計算梯度向量及 *Hessian Matrix* 是必要的。

---

範例 7. 分別利用 *Steepest Descent Method*(5) 及 *Newton-Raphson Method*(3), 寫程式計算函數 (6) 的最小值。

---

運用演算法前，最好先將演算法的步驟寫下來 (作業1)，再利用紙筆推導函數的一次及二次導數，最後才進行程式的寫作。程式部分可以參考之前關於計算函數極值的單元，雖然是單一變數的程式，但其邏輯卻是一致的，可以直接套用，再來修改。

圖 6 寫出 steepest descent 演算法的過程。當比較簡單的 steepest descent 演算法成功後，牛頓法便可以直接套用，其差別只在第 15 行後面加入 Hessian matrix 的計算，並在第 18 行修正  $x_{k1}$  的計算。

圖 6 的程式執行時，會列印出每個迴圈的結果（見圖右上角），包含函數值與  $x$  的位置。這個動作方便觀察程式是否出錯，也可以感受不同演算法的執行效率。做法請參考第 12 行的 fprintf 指令，這個指令類似 C 語言的 printf，使用方式非常豐富，圖上展示的方式分為兩個部分，即單引號及後面的變數部分。單引號裡面放置欲表達的輔助文字與列印變數內容的格式，如 %10.7f，意思是以浮點（floating point）的方式顯示變數內容，其中小數點以下 7 位，整數 2 位，加上小數點也算一位，共 10 位。引號後面，依序擺上欲列印內容的變數名稱。請注意單引號最後面的 \n 代表跳行。

```

1 clear
2 [X,Y]=meshgrid(1:0.05:3,-2:0.05:0);
3 Z=(X-2).^4+((X-2).^2).*(Y.^2)+(Y+1).^2;
4 contour(X,Y,Z,20)
5 N=20;
6 beta=0.5^(0:N-1);
7 f=@(x,y) (x-2)^4+((x-2)^2).*(y^2)+(y+1)^2;
8 %%%%%%%%%%%%%%%
9 xk=[2.8 -0.1];%初始值
10 fk=f(xk(1),xk(2));
11 while 1
12     fprintf('函數值 f(x)=%10.7f  x=%7.5f  y=%7.5fn', fk, xk(1),xk(2))%列印過程
13     text(xk(1),xk(2),'X') %追蹤過程
14     pause(1)
15     fp = -[4*(xk(1)-2)^3+2*(xk(1)-2)*xk(2)^2 ; 2*(xk(1)-2)^2*xk(2)+2*(xk(2)+1)];
16 %--- 步伐調整 ---
17     for j=1:N
18         xk1=xk +beta(j)*fp;% steepest descent
19         fk1=f(xk1(1),xk1(2));
20         if fk1 < fk; break;end
21     end
22     if abs(fk1-fk) <10^(-6),break,end
23     xk=xk1; %接受 xk1，重設定為 xk 繼續下一次遞迴
24     fk=fk1; %同上
25 end

```

Command Window

To get started, select [MATLAB Help](#) or [Demos](#) from the Help menu.

函數值 f(x)= 1.2260000 x=2.80000 y=-0.10000

函數值 f(x)= 0.0541480 x=1.76800 y=-0.93600

函數值 f(x)= 0.0506347 x=2.22446 y=-0.96324

函數值 f(x)= 0.0023924 x=1.99358 y=-0.95147

函數值 f(x)= 0.0023772 x=2.00520 y=-1.04845

函數值 f(x)= 0.0000003 x=1.99948 y=-0.99997

>>

圖 6: Steepest descent 演算法程式

圖6的程式還運用了空照圖，畫出 steepest descent 演算法的移動過程，如圖??。第 13 行為每個  $x_k$  的位置化下一個 X，第 14 行暫停 1 秒鐘，分辨觀察。這些都是寫程式時可以做為程式偵錯與欣賞演算法的小技巧。除此之外，第 23,24 行是初學者最容易疏忽的地方，將新的位置 ( $x_{k+1}$ ) 設定回舊的位置 ( $x_k$ )，才能在演算法中產生遞迴的效應，初學者不可不詳辨焉。




圖 7: Steepest descent 演算法程式:  $x$  的移動過程

能力未敷之際，切忌憑空築樓，否則程式錯了不容易除錯。另外計算目標函數值時，可以使用匿名函數的方式，讓整個程式看起來更簡潔。由於 Newton-Raphson 牽涉到 Hessian Matrix 的二次導數，有時候推導起來非常繁複。因此，簡單的 steepest descent 法通常是演算法的首選。不過我們還是可以利用這個簡單的函數，來看看兩者的收斂情況。

### 3 觀察

1. 不論是式 (3) 的 Steepest Descent 或式 (5) 的 Newton-Raphson 的移動

方向, 都不能保證可以帶領函數值往下探底, 因此所謂的「步伐調整」

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \beta \mathbf{d}_k$$

仍是必須的。請參考前章「演算法: 計算函數的極值」關於「步伐調整器」 $\beta$ 的選擇。

2. 關於 Newton-Raphson method 的合理性、限制, 請參考[1], 或從作業2中略探一二。
3. 仔細觀察不同的  $\mathbf{d}_k$ (式 (3) 與式 (5)) 在程式進行過程的收斂速度。甚至可以記錄過程中的函數值, 再繪製函數值隨著方向迭代的次數逐漸下降的趨勢。參考文獻[1]提供兩者收斂速度的理論分析。

## 4 作業

1. 請寫出適當的演算法, 用以計算函數的最小值。
2. Newton-Raphson method 的方向選擇, 如式(3), 可由函數的泰勒展開式得到驗證。多變量函數  $f(\mathbf{x}_{k+1})$  的泰勒展開式寫為

$$f(\mathbf{x}_{k+1}) = f(\mathbf{x}_k + \mathbf{d}_k) = f(\mathbf{x}_k) + \nabla f(\mathbf{x})^T \mathbf{d}_k + \frac{1}{2} \mathbf{d}_k^T \nabla^2 f(\mathbf{x}) \mathbf{d}_k + O(\|\mathbf{d}_k\|^3)$$

假設  $\|\mathbf{d}_k\|$  夠小, 可以省略  $O(\|\mathbf{d}_k\|^3)$ , 證明式 (3) 的 Newton-Raphson direction 為下列最小值問題的解

$$\min_{\mathbf{d}_k} f(\mathbf{x}_{k+1})$$

3. 著名的 Rosenbrock's Banana 測試函數

$$f(x, y) = 100(y - x^2)^2 + (1 - x)^2$$

常被用來測試極值演算法, 請試著繪製其立體圖 (mesh) 與空照圖 (contour), 再利用本單元介紹的兩個方法計算最小值, 並比較其收斂的情況。

4. 自行找一個兩個變數的函數，繪製函數圖 (mesh 與 contour) 並計算最小值。
5. 比較不同的迭代方向式 (3) 與式 (5) 的收斂速度，譬如到達同一個函數值所花的時間。此時可以觀察幾個不同函數值，由大到小，分別記錄兩種不同方式所花的時間，最後畫出一張圖比較兩者收斂的情況；橫軸代表「函數值」由大到小，縱軸代表時間。注意：除  $\mathbf{d}_k$  不同外，其他條件必須相同，譬如起始點。
6. 估計下列 MLE 問題

$$\max_{\alpha, \beta} \log L(\alpha, \beta)$$

其中的概似函數為

$$L(\alpha, \beta) = \prod_{i=1}^n f_t(v_i; \alpha, \beta) F_T(u_i; \alpha, \beta)^{-1}$$

where

$$f_t(v; \alpha, \beta) = \alpha \beta v^{\beta-1} \exp(-\alpha v^\beta)$$

$$F_T(u; \alpha, \beta) = 1 - \exp(-\alpha u^\beta)$$

變數  $u, v$  的  $n$  個樣本已知，請至下列網址下載該樣本資料檔 UV.txt。

<http://web.ntpu.edu.tw/~ccw/statmath/book.htm> ,「多變量函數的最小值」。

7. 匿名函數的使用可以非常簡單直接，也可能拐彎抹角的有點複雜，但如果能巧妙運用，往往可以解決看起來極困難的問題。譬如以下的問題：  
假設兩獨立變數  $X, Y$  分別服從  $\beta$  分配，其 PDF 為  $f_X(x) = \beta(x|a_1, b_1)$ ， $f_Y(x) = \beta(x|a_2, b_2)$ 。建立一新變數  $Z$

$$Z = XY$$

變數  $Z$  並不服從  $\beta$  分配，但我們想以一  $\beta$  分配， $\beta(a, b)$  來近似  $Z$  的分配，做法如下



$$\min_{a,b} \int_0^1 (f(z) - \beta(z|a,b))^2 dz$$

其中  $f(z)$  為變數  $Z$  的真實 PDF, 經過推演後寫成

$$f(z) = \int_z^1 f_Y(y) f_X(z/y) \frac{1}{y} dy$$

其中 Beta 函數  $f_X(x), f_Y(x)$  的參數分別指定為  $a_1 = b_1 = a_2 = b_2 = 2$ 。

請估計上述極小值問題的參數  $a, b$ 。

Hint:

- 其中積分與最小值的部分可以採 quad 及 fminsearch 指令。
- Beta 函數則使用 betapdf(x,2,2)。
- 當匿名函數的方式且匿名函數比較複雜時, 可以搭配副程式 (function) 將複雜的部分拉到副程式去做。

8. 前面的範例應用了最大概似估計法, 估計了混合  $\beta$  分配的參數。另一個常見的問題是混合常態的參數估計。即,

$$\max_{\Omega=\{\pi_1, \pi_2, \mu_1, \sigma_1^2, \mu_2, \sigma_2^2\}, \pi_1+\pi_2=1, \pi_1>0, \pi_2>0} L(\Omega)$$

其中概似函數為

$$L(\Omega) = \sum_{i=1}^N \ln(\pi_1 f(x|\mu_1, \sigma_1^2) + \pi_2 f(x|\mu_2, \sigma_2^2))$$

$f(x|\mu, \sigma^2)$  為常態分配的機率密度函數。請自行產生適用的資料並運用 fminsearchcon 估計參數  $\Omega = \{\pi_1, \mu_1, \sigma_1^2, \mu_2, \sigma_2^2\}$ 。

## 參考文獻

- [1] J.E. Dennis, R.B. Schnabel, "Numerical Methods for Unconstrained Optimization," Prentice Hall.

```
[ab,hval]=fminsearch(@(a) quad(@(z)( fun_z(z)-betapdf(z,a(1),a(2))).^2,0,1),[5,5]);
```

```
function k=fun_z(z)
    k=zeros(size(z));
    for i=1:length(z)
        w=@(y)betapdf(y,2,2).*betapdf(z(i)./y,2,2)./y;
        k(i)=quad(w,z(i),1);
    end
```