

PSI 2533

Lista 1 — Módulo de Filtragem Adaptativa

Prof. Vítor H. Nascimento

15 de outubro de 2014

Nesta lista vamos estudar um pouco o problema de achar o mínimo de uma função diferenciável, o algoritmo do gradiente, e recordar algumas propriedades de processos estocásticos.

Antes, vamos precisar de duas definições e de um teorema:

Definição: A matriz $\mathbf{A} \in \mathbb{R}^{M \times M}$ é dita *positiva-definida* se, para qualquer vetor $\mathbf{x} \in \mathbb{R}^M$ diferente do vetor nulo valer

$$\mathbf{x}^T \mathbf{A} \mathbf{x} > 0.$$

A matriz é *positiva semi-definida* se valer, para qualquer vetor $\mathbf{x} \in \mathbb{R}^M$,

$$\mathbf{x}^T \mathbf{A} \mathbf{x} \geq 0.$$

Definição: A *hessiana* de uma função de várias variáveis $f(x_1, \dots, x_M)$ é a matriz \mathbf{H}

$$\mathbf{H}(x_1, \dots, x_M) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots \\ \vdots & \vdots & \ddots \end{bmatrix}$$

Teorema: Toda matriz $n \times n$ simétrica (isto é, $\mathbf{A} = \mathbf{A}^T$) pode ser diagonalizada por uma matriz \mathbf{Q} tal que $\mathbf{Q}^T \mathbf{Q} = \mathbf{I}$ (a matriz identidade — diz-se que \mathbf{Q} é *ortogonal* ou *unitária*). Além disso, todos os seus autovalores são números reais. Assim, temos:

$$\mathbf{Q}^T \mathbf{A} \mathbf{Q} = \mathbf{\Lambda} = \text{diag}(\lambda_i) = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_M \end{bmatrix},$$

com $\lambda_i \in \mathbb{R}$, $1 \leq i \leq M$.

Exercícios:

1. Mostre que as colunas de \mathbf{Q} são autovetores de \mathbf{A} . Quais são os autovalores correspondentes?
2. Considere a função de várias variáveis

$$f(x_1, x_2, \dots, x_M) = \begin{bmatrix} x_1 & x_2 & \cdots & x_M \end{bmatrix} \mathbf{A} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_M \end{bmatrix},$$

em que $\mathbf{A} \in \mathbb{R}^{M \times M}$ é uma matriz qualquer. Mostre que sempre é possível reescrever f em termos de uma matriz \mathbf{R} simétrica. Mostre como obter \mathbf{R} a partir de \mathbf{A} . Dica: lembre que $\mathbf{y}^T = y$ se y for um escalar. Qual é expressão da transposta de f ?

3. Mostre que a matriz simétrica $\mathbf{R} \in \mathbb{R}^{M \times M}$ é positiva-definida se e somente se todos os seus autovalores forem positivos. A matriz será positiva semi-definida se os autovalores forem maiores ou iguais a zero. Dica: use a forma diagonalizada da matriz.
4. Considere a função de várias variáveis

$$f(\mathbf{x}) = c + 2\mathbf{x}^T \mathbf{b} + \mathbf{x}^T \mathbf{R} \mathbf{x},$$

em que c é uma constante (real), $\mathbf{b} \in \mathbb{R}^M$ é um vetor constante e $\mathbf{R} \in \mathbb{R}^{M \times M}$ é uma matriz simétrica.

- (a) Mostre que o ponto em que o gradiente de f se anula é $\mathbf{x}_* = -\mathbf{R}^{-1} \mathbf{b}$.
- (b) Calcule a hessiana de $f(\mathbf{x})$.
- (c) Mostre que \mathbf{x}_* é um ponto de mínimo se e somente \mathbf{R} for positiva semi-definida, e um ponto de máximo se $-\mathbf{R}$ for positiva semi-definida.
- (d) Considere $c = 1$, $\mathbf{b} = [1 \quad -1]^T$ e três casos para \mathbf{R} :

- i. $\mathbf{R} = \begin{bmatrix} 1 & 0,5 \\ 0,5 & 1 \end{bmatrix}$,
- ii. $\mathbf{R} = \begin{bmatrix} 1 & 0,5 \\ 0,5 & 0,2 \end{bmatrix}$,
- iii. $\mathbf{R} = \begin{bmatrix} -1 & 0,5 \\ 0,5 & -0,5 \end{bmatrix}$.

Para cada caso, determine se o \mathbf{x}_* é um ponto de mínimo ou de máximo. Use a função `contour` do Matlab para desenhar as curvas de nível de f em cada caso, e ver o que acontece.

- (e) Para o(s) caso(s) em que \mathbf{x}_* é um ponto de mínimo, determine a faixa de passo μ para a qual o algoritmo do gradiente converge para \mathbf{x}_* , começando de uma condição inicial qualquer. Teste o resultado no programa que você fez em aula.
5. Suponha agora que $f(\mathbf{x})$ seja uma função de várias variáveis, com gradiente $\nabla f(\mathbf{x})$ e hessiana $\mathbf{H}(\mathbf{x})$. A função pode ser expandida em série de Taylor em torno de um ponto \mathbf{x} qualquer, assim:

$$f(\mathbf{y}) \approx f(\mathbf{x}) + (\mathbf{y} - \mathbf{x})^T \nabla f(\mathbf{x}) + \frac{1}{2} (\mathbf{y} - \mathbf{x})^T \mathbf{H}(\mathbf{x}) (\mathbf{y} - \mathbf{x}).$$

Mostre que os mínimos de f ocorrem nos pontos \mathbf{x}_* tais que $\nabla f(\mathbf{x}_*) = \mathbf{0}$, e $\mathbf{H}(\mathbf{x}_*)$ é positiva definida.

Recordação de processos estocásticos:

1. Considere o vetor de variáveis aleatórias $\mathbf{x} = [x_1 \quad \dots \quad x_M]^T$. Mostre que a matriz de autocorrelação $\mathbf{R} = \mathbf{E}\{\mathbf{x}\mathbf{x}^T\}$ é sempre positiva semi-definida. Dica: calcule $\mathbf{E}\{y^2\}$, em que $y = \mathbf{b}^T \mathbf{x}$, e \mathbf{b} é um vetor constante.
2. Considere um ruído branco Gaussiano $x[n]$ com média nula e potência média 2. Imagine que $x[n]$ passa por um filtro com resposta ao impulso $h[n]$, em que $h[0] = 1$, $h[1] = 0.5$ e $h[n] = 0$ para todos os outros valores de n . Calcule a média e a função de autocorrelação de $y[n]$.