

Otimização Não-Linear – Primeira Prova

20 de outubro de 2023

1

Dizemos que $\mathbf{d} \in \mathbb{R}^n$ é uma direção de descida para $f : \mathbb{R}^n \rightarrow \mathbb{R}$ a partir de $\mathbf{x} \in \mathbb{R}^n$ quando existe $\Lambda > 0$ tal que para todo $\lambda \in (0, \Lambda]$ temos

$$f(\mathbf{x} + \lambda \mathbf{d}) < f(\mathbf{x}).$$

Prove que se f é diferenciável em \mathbf{x} e $\mathbf{d}^T \nabla f(\mathbf{x}) < 0$, então \mathbf{d} é uma direção de descida.

2

Prove que um minimizador \mathbf{x}^* de uma função diferenciável $f : \mathbb{R}^n \rightarrow \mathbb{R}$ satisfaz $\nabla f(\mathbf{x}^*) = \mathbf{0}$. Dica: utilize o resultado da Questão 1.

3

Considere o problema irrestrito $\min\{f_\gamma(\mathbf{x}) := \|\mathbf{A}\mathbf{x} - \mathbf{b}\|_2^2 + \gamma\|\mathbf{x}\|_1\}$ e denote por \mathbf{x}_γ^* a sua solução. Prove que se $\alpha > \beta$ então $f_\alpha(\mathbf{x}_\alpha^*) \geq f_\beta(\mathbf{x}_\beta^*)$. Generalize.

4

Considere o seguinte algoritmo de gradientes conjugados:

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \lambda_k \mathbf{d}^k$$

onde

$$\lambda_k = \arg \min f(\mathbf{x}^k + \lambda \mathbf{d}^k),$$
$$\beta_k = \frac{\nabla f(\mathbf{x}^k)^T (\nabla f(\mathbf{x}^k) - \nabla f(\mathbf{x}^{k-1}))}{\nabla f(\mathbf{x}^{k-1})^T \nabla f(\mathbf{x}^{k-1})} \quad \text{e} \quad \mathbf{d}^k = -\nabla f(\mathbf{x}^k) + \beta_k \mathbf{d}^{k-1}.$$

Mostre que \mathbf{d}^k é uma direção de descida para f a partir de \mathbf{x}^k . Dica: utilize-se do fato de termos busca linear exata para mostrar que $\nabla f(\mathbf{x}^k)^T \mathbf{d}^{k-1} = 0$ e também utilize o resultado da questão 1.