

最优化作业 2

龚舒凯 2022202790

1. 考虑采用精确线搜索的最速下降法，用于强凸二次函数。证明当初始点 \mathbf{x}_0 满足 $\mathbf{x}_0 - \mathbf{x}^*$ 平行于 Hessian 矩阵 \mathbf{Q} 的特征向量时，最速下降法只需要一步就可以找到最小点。(20 分)

证明. 设强凸二次函数为 $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^\top \mathbf{G}\mathbf{x} + \mathbf{b}^\top \mathbf{x} + \frac{m}{2}\mathbf{x}^\top \mathbf{x}$ ，其中 \mathbf{G} 为正定矩阵， \mathbf{b} 为常向量， m 为强凸参数。先重写强凸二次函数为

$$f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^\top \mathbf{G}\mathbf{x} + \mathbf{b}^\top \mathbf{x} + \frac{m}{2}\mathbf{x}^\top \mathbf{x} = \frac{1}{2}\mathbf{x}^\top (\mathbf{G} + m\mathbf{I})\mathbf{x} + \mathbf{b}^\top \mathbf{x} \triangleq \frac{1}{2}\mathbf{x}^\top \mathbf{Q}\mathbf{x} + \mathbf{b}^\top \mathbf{x} \quad (1)$$

显然 $\mathbf{Q} = \mathbf{G} + m\mathbf{I}$ 是正定矩阵。由题意， $\mathbf{x}_0 - \mathbf{x}^*$ 是 \mathbf{Q} 的特征向量，那么 $\exists \lambda \in \mathbb{R}$,

$$\mathbf{Q}(\mathbf{x}_0 - \mathbf{x}^*) = \lambda(\mathbf{x}_0 - \mathbf{x}^*) \quad (2)$$

在最小点 \mathbf{x}^* 处， $\mathbf{g}(\mathbf{x}) = \nabla f(\mathbf{x}^*) = \mathbf{Q}\mathbf{x}^* + \mathbf{b} = \mathbf{0}$ ，那么初始点 \mathbf{x}_0 处的梯度可以表示为

$$\mathbf{g}_0 = \mathbf{Q}\mathbf{x}_0 + \mathbf{b} = \mathbf{Q}\mathbf{x}_0 - \mathbf{Q}\mathbf{x}^* = \lambda(\mathbf{x}_0 - \mathbf{x}^*) \quad (3)$$

最速下降法的下降方向为 $\mathbf{d}_0 = -\mathbf{g}_0$ ，根据精确线搜索可确定搜索步长为

$$\alpha_0 = \arg \min_{\alpha} f(\mathbf{x}_0 - \alpha \mathbf{g}_0) = \frac{\mathbf{g}_0^\top \mathbf{g}_0}{\mathbf{g}_0^\top \mathbf{Q} \mathbf{g}_0} = \frac{\lambda^2 (\mathbf{x}_0 - \mathbf{x}^*)^\top (\mathbf{x}_0 - \mathbf{x}^*)}{\lambda^2 (\mathbf{x}_0 - \mathbf{x}^*)^\top \mathbf{Q} (\mathbf{x}_0 - \mathbf{x}^*)} \quad (4)$$

$$= \frac{\lambda^2 (\mathbf{x}_0 - \mathbf{x}^*)^\top (\mathbf{x}_0 - \mathbf{x}^*)}{\lambda^3 (\mathbf{x}_0 - \mathbf{x}^*)^\top (\mathbf{x}_0 - \mathbf{x}^*)} = \frac{1}{\lambda} \quad (5)$$

因此最速下降法走过一步后，

$$\mathbf{x}_1 = \mathbf{x}_0 - \alpha_0 \mathbf{g}_0 = \mathbf{x}_0 - \frac{1}{\lambda} \lambda (\mathbf{x}_0 - \mathbf{x}^*) = \mathbf{x}^* \quad (6)$$

因此在题设条件下，最速下降法只需要一步就可以找到最小点。 \square

2. 假设 \mathbf{Q} 是一个正定对称矩阵，证明如下 Kantorovich 不等式

$$\frac{(\mathbf{x}^\top \mathbf{x})^2}{(\mathbf{x}^\top \mathbf{Q} \mathbf{x})(\mathbf{x}^\top \mathbf{Q}^{-1} \mathbf{x})} \geq \frac{4\lambda_n \lambda_1}{(\lambda_n + \lambda_1)^2} \quad (7)$$

其中， λ_n, λ_1 分别为 \mathbf{Q} 的最大、最小特征值， \mathbf{x} 为任意非 $\mathbf{0}$ 向量。(该题目有一定的难度)(20 分)

证明. 由于 \mathbf{Q} 为正定对称阵，可对其作特征值分解 $\mathbf{Q} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^\top$ ，其中 $\mathbf{U} = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_n]$ 为正交矩阵， $\mathbf{\Lambda}$ 为对角矩阵，对角元素为 \mathbf{Q} 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 。于是要证的不等式可转化为

$$\frac{(\mathbf{x}^\top \mathbf{x})^2}{((\mathbf{U}^\top \mathbf{x})^\top \mathbf{\Lambda} \mathbf{U}^\top \mathbf{x})((\mathbf{U}^\top \mathbf{x})^\top \mathbf{\Lambda}^{-1} \mathbf{U}^\top \mathbf{x})} \stackrel{\mathbf{y}=\mathbf{U}^\top \mathbf{x}}{=} \frac{(\mathbf{y}^\top (\mathbf{U}^\top \mathbf{U})^{-1} \mathbf{y})^2}{(\mathbf{y}^\top \mathbf{\Lambda} \mathbf{y})(\mathbf{y}^\top \mathbf{\Lambda}^{-1} \mathbf{y})} \quad (8)$$

$$= \frac{\left(\sum_{i=1}^n y_i^2\right)^2}{\left(\sum_{i=1}^n \lambda_i y_i^2\right)\left(\sum_{i=1}^n \lambda_i^{-1} y_i^2\right)} \geq \frac{4\lambda_n \lambda_1}{(\lambda_n + \lambda_1)^2} \quad (9)$$

记 $p_i = \frac{y_i^2}{\sum_{i=1}^n y_i^2} \geq 0$, 显然 $\sum_{i=1}^n p_i = 1$, 要证明的不等式可进一步转化为

$$\frac{1}{\left(\sum_{i=1}^n \lambda_i p_i\right) \left(\sum_{i=1}^n \lambda_i^{-1} p_i\right)} \geq \frac{4\lambda_n \lambda_1}{(\lambda_n + \lambda_1)^2} \quad (10)$$

记 $f(\mathbf{p}) = \left(\sum_{i=1}^n \lambda_i p_i\right) \left(\sum_{i=1}^n \lambda_i^{-1} p_i\right)$, 我们先证明一个引理:

$$\left(\sum_{i=1}^n \lambda_i p_i\right) \left(\sum_{i=1}^n \lambda_i^{-1} p_i\right) = 1 - \sum_{i=1}^n p_i (\lambda_i - \sum_{i=1}^n \lambda_i p_i) (\lambda_i^{-1} - \sum_{i=1}^n \lambda_i^{-1} p_i) \quad (11)$$

记 $A = \sum_{i=1}^n \lambda_i p_i$, $B = \sum_{i=1}^n \lambda_i^{-1} p_i$, 那么

$$(11) \iff AB = 1 - \sum_{i=1}^n p_i (\lambda_i - A) (\lambda_i^{-1} - B) \quad (12)$$

$$\iff AB = 1 - \sum_{i=1}^n (\lambda_i \lambda_i^{-1} p_i - \lambda_i B p_i - A \lambda_i^{-1} p_i - AB p_i) \quad (13)$$

$$\iff AB = 1 - \sum_{i=1}^n p_i + B \sum_{i=1}^n \lambda_i p_i + A \sum_{i=1}^n \lambda_i^{-1} p_i + AB \sum_{i=1}^n p_i \quad (14)$$

$$\iff AB = 1 - 1 + AB + AB - AB \quad (15)$$

$$\iff AB = AB \quad \text{于是引理显然得证} \quad (16)$$

再对引理使用 Cauchy 不等式:

$$f(\mathbf{p}) = 1 - \sum_{i=1}^n p_i (\lambda_i - \sum_{i=1}^n \lambda_i p_i) (\lambda_i^{-1} - \sum_{i=1}^n \lambda_i^{-1} p_i) \quad (17)$$

$$\leq 1 + \sqrt{\sum_{i=1}^n p_i (\lambda_i - \sum_{i=1}^n \lambda_i p_i)^2} \sqrt{\sum_{i=1}^n p_i (\lambda_i^{-1} - \sum_{i=1}^n \lambda_i^{-1} p_i)^2} \quad (18)$$

又注意到

$$\sum_{i=1}^n p_i (\lambda_i - \sum_{i=1}^n \lambda_i p_i)^2 = \min_{a \in \mathbb{R}} \sum_{i=1}^n p_i (\lambda_i - a)^2 \leq \sum_{i=1}^n p_i (\lambda_i - \frac{\lambda_1 + \lambda_n}{2})^2 \quad (19)$$

$$\leq \sum_{i=1}^n p_i (\lambda_n - \frac{\lambda_1 + \lambda_n}{2})^2 = (\frac{\lambda_n - \lambda_1}{2})^2 \quad (20)$$

因此

$$f(\mathbf{p}) \leq 1 + \frac{\lambda_n - \lambda_1}{2} \cdot \frac{\lambda_1^{-1} - \lambda_n^{-1}}{2} = 1 + \frac{(\lambda_n - \lambda_1)^2}{4\lambda_n \lambda_1} = \frac{(\lambda_n + \lambda_1)^2}{4\lambda_1 \lambda_n} \quad (21)$$

从而不等式 (9)

$$\frac{1}{f(\mathbf{p})} \geq \frac{4\lambda_1 \lambda_n}{(\lambda_n + \lambda_1)^2} \quad (22)$$

这证明了 Kantorovich 不等式。 □

3. 拟牛顿条件为 $\mathbf{B}_{k+1}\mathbf{s}_k = \mathbf{y}_k$ ，为了保证 \mathbf{B}_{k+1} 正定，要求 $\mathbf{s}_k^\top \mathbf{y}_k > 0$ ，证明当目标函数 f 强凸时，该条件一定满足。(20分)

证明. 规定 $\mathbf{s}_k = \mathbf{x}_{k+1} - \mathbf{x}_k$ ， $\mathbf{y}_k = \nabla f(\mathbf{x}_{k+1}) - \nabla f(\mathbf{x}_k)$ 。先指出一个引理：当 f 为凸函数时，成立 $\mathbf{s}_k^\top \mathbf{y}_k \geq 0$ 。证明如下：由 f 的凸性，有

$$\begin{cases} f(\mathbf{x}_{k+1}) \geq f(\mathbf{x}_k) + \nabla f(\mathbf{x}_k)^\top (\mathbf{x}_{k+1} - \mathbf{x}_k) \\ f(\mathbf{x}_k) \geq f(\mathbf{x}_{k+1}) + \nabla f(\mathbf{x}_{k+1})^\top (\mathbf{x}_k - \mathbf{x}_{k+1}) \end{cases} \Rightarrow 0 \geq (\nabla f(\mathbf{x}_k) - \nabla f(\mathbf{x}_{k+1}))^\top (\mathbf{x}_{k+1} - \mathbf{x}_k) \quad (23)$$

$$\Rightarrow -\mathbf{y}_k^\top \mathbf{s}_k \leq 0 \Rightarrow \mathbf{s}_k^\top \mathbf{y}_k \geq 0 \quad (24)$$

当 f 为强凸函数时，存在强凸参数 $m > 0$ ，使得 $g(\mathbf{x}) = f(\mathbf{x}) - \frac{m}{2}\mathbf{x}^\top \mathbf{x}$ 为凸函数。对 $g(\mathbf{x})$ 求梯度得 $\nabla g(\mathbf{x}) = \nabla f(\mathbf{x}) - m\mathbf{x}$ 。由于 g 为凸函数，根据引理

$$(\mathbf{x}_{k+1} - \mathbf{x}_k)^\top (\nabla g(\mathbf{x}_{k+1}) - \nabla g(\mathbf{x}_k)) \quad (25)$$

$$= (\mathbf{x}_{k+1} - \mathbf{x}_k)^\top (\nabla f(\mathbf{x}_{k+1}) - \nabla f(\mathbf{x}_k) - m(\mathbf{x}_{k+1} - \mathbf{x}_k)) \quad (26)$$

$$= (\mathbf{x}_{k+1} - \mathbf{x}_k)^\top (\nabla f(\mathbf{x}_{k+1}) - \nabla f(\mathbf{x}_k)) - m\|\mathbf{x}_{k+1} - \mathbf{x}_k\|^2 \geq 0 \quad (27)$$

从而 $\mathbf{s}_k^\top \mathbf{y}_k \geq m\|\mathbf{s}_k\|^2 > 0$ ，即当目标函数 f 强凸时，拟牛顿条件一定满足。□

4. 证明采用强 Wolfe 准则，可以保证 $\mathbf{s}_k^\top \mathbf{y}_k > 0$ ，即可以保证 \mathbf{B}_{k+1} 的正定性。(上课证明了精确线搜索和 Wolfe，这里要求证明强 Wolfe) (10分)

证明. 由强 Wolfe 准则的第二个条件知

$$|g(\mathbf{x}_k + \alpha_k \mathbf{d}_k)^\top \mathbf{d}_k| = |\mathbf{g}_{k+1}^\top \mathbf{d}_k| \leq -\sigma \mathbf{g}_k^\top \mathbf{d}_k, \quad \sigma \in (0, 1) \quad (28)$$

于是

$$\mathbf{s}_k^\top \mathbf{y}_k = \alpha_k \mathbf{d}_k^\top (\mathbf{g}_{k+1} - \mathbf{g}_k) = \alpha_k (\mathbf{g}_{k+1}^\top \mathbf{d}_k - \mathbf{g}_k^\top \mathbf{d}_k) > \alpha_k (\sigma - 1) \mathbf{g}_k^\top \mathbf{d}_k > 0 \quad (29)$$

□

5. $f(\mathbf{x})$ 为正定二次函数，采用 SR1 方法进行优化，假设在迭代过程中一直满足 $(\mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k)^\top \mathbf{y}_k > 0$ ，证明：

$$\mathbf{H}_k \mathbf{y}_j = \mathbf{s}_j, \quad j = 0, 1, \dots, k-1 \quad (30)$$

(该题目试图证明 SR1 方法更新出来的 \mathbf{H}_k 不但和前一步的 $\mathbf{y}_{k-1}, \mathbf{s}_{k-1}$ 满足拟牛顿条件，而且还和之前所有步的 $\mathbf{y}_j, \mathbf{s}_j$ 都满足拟牛顿条件。事实上在共轭梯度章节的 Broyden 族方法的共轭特性介绍中，我们也得到了相似的结论 (20分)

证明. 使用数学归纳法证明：

1. 当 $k = 1$ 时， $\mathbf{H}_1 \mathbf{y}_0 = \mathbf{s}_0$ 显然成立 (拟牛顿条件)。
2. 设当 $k = n$ 时， $\mathbf{H}_n \mathbf{y}_j = \mathbf{s}_j, j = 0, 1, \dots, n-1$ 成立，那么当 $k = n+1$ 时

- (1) 若 $i = n$, $\mathbf{H}_{n+1}\mathbf{y}_n = \mathbf{s}_n$ (拟牛顿条件) 显然成立。
 (2) 若 $i \in \{0, \dots, n-1\}$, 则由 SR1 法的更新公式,

$$\mathbf{H}_{n+1}\mathbf{y}_i = \mathbf{H}_n\mathbf{y}_i + \frac{(\mathbf{s}_n - \mathbf{H}_n\mathbf{y}_n)(\mathbf{s}_n - \mathbf{H}_n\mathbf{y}_n)^\top \mathbf{y}_i}{(\mathbf{s}_n - \mathbf{H}_n\mathbf{y}_n)^\top \mathbf{y}_n} \quad (31)$$

$$= \mathbf{H}_n\mathbf{y}_i + \frac{(\mathbf{s}_n - \mathbf{H}_n\mathbf{y}_n)(\mathbf{s}_n^\top \mathbf{y}_i - \mathbf{y}_n^\top \mathbf{H}_n^\top \mathbf{y}_i)}{(\mathbf{s}_n - \mathbf{H}_n\mathbf{y}_n)^\top \mathbf{y}_n} \quad (32)$$

其中

$$\mathbf{s}_n^\top \mathbf{y}_i - \mathbf{y}_n^\top \mathbf{H}_n^\top \mathbf{y}_i = (\mathbf{G}^{-1}\mathbf{y}_n)^\top \mathbf{y}_i - \mathbf{y}_n^\top \mathbf{s}_i = \mathbf{y}_n^\top \mathbf{G}^{-1}\mathbf{y}_i - \mathbf{y}_n^\top \mathbf{s}_i \quad (33)$$

$$= \mathbf{y}_n^\top \mathbf{s}_i - \mathbf{y}_n^\top \mathbf{s}_i = 0 \quad (34)$$

因此 $\mathbf{H}_{n+1}\mathbf{y}_i = \mathbf{H}_n\mathbf{y}_i = \mathbf{s}_i$

3. 即当 $k = n + 1$ 时, $\mathbf{H}_{n+1}\mathbf{y}_j = \mathbf{s}_j$, $j = 0, 1, \dots, n$ 成立。由数学归纳法, 结论得证。 \square

6. 对于一个正定二次函数 $\phi(\mathbf{x}) = \frac{1}{2}\mathbf{x}^\top \mathbf{A}\mathbf{x} - \mathbf{b}^\top \mathbf{x}$, 假设我们已经得到了一套共轭方向 $\mathbf{p}_0, \dots, \mathbf{p}_l$, 满足 $\mathbf{p}_i^\top \mathbf{A}\mathbf{p}_j = 0$, $i \neq j$, 我们按照如下的方式进行迭代:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k \quad (35)$$

请证明: 如果步长采用精确线搜索, 那么 $\alpha_k = -\frac{\mathbf{g}_k^\top \mathbf{p}_k}{\mathbf{p}_k^\top \mathbf{A}\mathbf{p}_k}$, 其中 $\mathbf{g}_k = \mathbf{A}\mathbf{x}_k - \mathbf{b}$ 。如果我们进一步假设这套共轭方法是按照线性共轭梯度法得到的, 这个步长的公式是否可以进一步简化? (10 分)

证明. 首先

$$\phi(\mathbf{x}_k + \alpha_k \mathbf{p}_k) = \frac{1}{2}(\mathbf{x}_k + \alpha_k \mathbf{p}_k)^\top \mathbf{A}(\mathbf{x}_k + \alpha_k \mathbf{p}_k) - \mathbf{b}^\top (\mathbf{x}_k + \alpha_k \mathbf{p}_k) \quad (36)$$

$$= \frac{1}{2}\mathbf{x}_k^\top \mathbf{A}\mathbf{x}_k + \alpha_k \mathbf{p}_k^\top \mathbf{A}\mathbf{x}_k + \frac{1}{2}\alpha_k^2 \mathbf{p}_k^\top \mathbf{A}\mathbf{p}_k - \mathbf{b}^\top (\mathbf{x}_k + \alpha_k \mathbf{p}_k) \quad (37)$$

$$(38)$$

关于 α_k 求导得

$$\frac{\partial \phi(\mathbf{x}_k + \alpha_k \mathbf{p}_k)}{\partial \alpha_k} = \mathbf{p}_k^\top \mathbf{A}\mathbf{x}_k + \alpha_k \mathbf{p}_k^\top \mathbf{A}\mathbf{p}_k - \mathbf{b}^\top \mathbf{p}_k = 0 \quad (39)$$

$$\Rightarrow \alpha_k = \frac{\mathbf{b}^\top \mathbf{p}_k - \mathbf{x}_k^\top \mathbf{A}\mathbf{p}_k}{\mathbf{p}_k^\top \mathbf{A}\mathbf{p}_k} = -\frac{(\mathbf{A}\mathbf{x}_k - \mathbf{b})^\top \mathbf{p}_k}{\mathbf{p}_k^\top \mathbf{A}\mathbf{p}_k} = -\frac{\mathbf{g}_k^\top \mathbf{p}_k}{\mathbf{p}_k^\top \mathbf{A}\mathbf{p}_k} \quad (40)$$

当共轭方向由线性共轭梯度法得到时, 第 k 次迭代方向 \mathbf{p}_k 满足

$$\mathbf{p}_k = -\mathbf{g}_k + \frac{\mathbf{g}_k^\top \mathbf{g}_{k-1}}{\mathbf{g}_{k-1}^\top \mathbf{g}_{k-1}} \mathbf{p}_{k-1} \quad (41)$$

且由子空间拓展定理知 $\mathbf{g}_k^\top \mathbf{p}_i = 0$, $i = 0, 1, \dots, k-1$ 。两边同时左乘 \mathbf{g}_k^\top , 得

$$\mathbf{g}_k^\top \mathbf{p}_k = -\mathbf{g}_k^\top \mathbf{g}_k + \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{g}_{k-1}^\top \mathbf{g}_{k-1}} \mathbf{g}_k^\top \mathbf{p}_{k-1} = -\mathbf{g}_k^\top \mathbf{g}_k \quad (42)$$

那么步长可以化简为 $\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{p}_k^\top \mathbf{A}\mathbf{p}_k}$ \square