



PROGRAD
Pró-Reitoria de
Graduação



Notas de estudo

Resumo Da Teoria de Otimização

João Matheus Lira Luiz

Vitória da Conquista, 2024

Conteúdo

1	Resultados Importantes	2
2	Existência de Soluções	3
2.1	Condições para Existência de Solução Global	4
3	Condições de Otimalidade	6
4	Convexidade	10
5	Classificação dos métodos e noções de convergência	16
5.1	Tipos de Convergência	17
5.2	Taxas de convergência. Regras de parada	18
6	Otimização irrestrita	19
6.1	Métodos de descida	19
6.2	Esquema geral dos métodos de descida	19
6.3	Buscas lineares	21
6.3.1	Regra de Minimização Unidimensional	21
6.3.2	Regra de Armijo	22
6.3.3	Regra de Goldstein	24
6.3.4	Regra de Wolfe	26
7	Método do gradiente	27

1 Resultados Importantes

Lema 1.1. *Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável em \mathbb{R}^n , com derivada Lipschitz-contínua no \mathbb{R}^n com módulo $L > 0$. Então, temos a desigualdade*

$$|f(x + d) - f(x) - \langle f'(x), d \rangle| \leq \frac{L\|d\|^2}{2}, \quad (1)$$

onde $d \in \mathbb{R}^n$.

Demonstração. Considere a função $\psi : [0, 1] \rightarrow \mathbb{R}$ dada por

$$\psi(t) = f(x + td) - f(x) - t\langle f'(x), d \rangle.$$

Note que, pela regra da cadeia, temos

$$\begin{aligned} \psi'(t) &= \langle f'(x + td), d \rangle - \langle f'(x), d \rangle \\ &= \langle f'(x + td) - f'(x), d \rangle. \end{aligned}$$

Além disso, observe que

$$\begin{aligned} f(x + d) - f(x) - \langle f'(x), d \rangle &= \psi(1) - \psi(0) \\ &= \int_0^1 \psi'(t) dt \\ &= \int_0^1 \langle f'(x + td) - f'(x), d \rangle dt. \end{aligned}$$

Agora, tomando o valor absoluto de ambos os lados, obtemos

$$\begin{aligned} |f(x + d) - f(x) - \langle f'(x), d \rangle| &= \left| \int_0^1 \langle f'(x + td) - f'(x), d \rangle dt \right| \\ &\leq \int_0^1 \|f'(x + td) - f'(x)\| \cdot \|d\| dt. \end{aligned}$$

Como a derivada de f é Lipschitz-contínua, sabemos que

$$\|f'(x + td) - f'(x)\| \leq L\|td\| = Lt\|d\|.$$

Logo, temos

$$\begin{aligned} \int_0^1 \|f'(x + td) - f'(x)\| \cdot \|d\| dt &\leq \int_0^1 Lt\|d\|^2 dt \\ &= L\|d\|^2 \int_0^1 t dt \\ &= L\|d\|^2 \cdot \frac{1}{2}. \end{aligned}$$

Portanto, concluímos que

$$|f(x + d) - f(x) - \langle f'(x), d \rangle| \leq \frac{L\|d\|^2}{2}.$$

□

□

2 Existência de Soluções

Sejam dados um conjunto $D \subset \mathbb{R}^n$ e uma função $f : \Omega \rightarrow \mathbb{R}$, onde $D \subset \Omega$. O objetivo é encontrar um minimizador de f no conjunto D :

$$\min f(x) \text{ sujeito a } x \in D \quad (2)$$

- **Conjunto viável:** o conjunto D .
- **Pontos viáveis:** os pontos de D .
- **Função objetivo:** a função f .

Definição 2.1. Dizemos que $\bar{x} \in D$ é:

- (a) **Minimizador global** de $f : \Omega \rightarrow \mathbb{R}$, se $f(\bar{x}) \leq f(x), \forall x \in D$.
- (b) **Minimizador local** de $f : \Omega \rightarrow \mathbb{R}$, se existe uma vizinhança U de \bar{x} tal que $f(\bar{x}) \leq f(x), \forall x \in D \cap U$.

Se para todo $x \neq \bar{x}$ as desigualdades são estritas, \bar{x} será chamado **minimizador estrito**.

Definição 2.2. Dizemos que $\bar{v} \in \mathbb{R}$, definido por $\bar{v} = \inf\{f(x); x \in D\}$, é o **valor ótimo** do problema.

Exemplo 2.1. Seja $f : \Omega \rightarrow \mathbb{R}$ definida por $f(x) = (x + 1)^2$, com $D = \Omega = \mathbb{R}$. Temos que:

- f é a função objetivo,
- $\bar{x} = -1$ é o minimizador global e estrito de f ,
- $\bar{v} = 0$ é o valor ótimo do problema.
- Uma função pode admitir vários minimizadores globais, mas o valor ótimo do problema é único.
- Todo minimizador global é um minimizador local, mas a recíproca não é verdadeira.
- Quando $\bar{v} = \infty$ ou $\bar{v} = -\infty$, o problema não possui solução global.

2.1 Condições para Existência de Solução Global

Teorema 2.1 (Teorema de Weierstrass). *Sejam $D \subset \mathbb{R}^n$ um conjunto compacto não vazio, e $f : D \rightarrow \mathbb{R}$ uma função contínua. Então o problema de minimizar f tem solução global.*

Demonstração. Como a imagem de um conjunto compacto por uma função contínua é um conjunto compacto, temos que $\{v \in \mathbb{R}; v = f(x), \text{ para } x \in D\}$ é um conjunto compacto. Em particular, é limitado inferiormente, ou seja, $-\infty < \bar{v} = \inf f(x)$.

Pela definição de ínfimo, $\forall k \in \mathbb{N}, \exists x^k \in D; \bar{v} \leq f(x^k) \leq \bar{v} + \frac{1}{k}$. Passando ao limite quando $k \rightarrow \infty$, temos:

$$\begin{aligned} \lim_{k \rightarrow \infty} \bar{v} &\leq \lim_{k \rightarrow \infty} f(x^k) \leq \lim_{k \rightarrow \infty} \left(\bar{v} + \frac{1}{k} \right) \\ \bar{v} &\leq \lim_{k \rightarrow \infty} f(x^k) \leq \bar{v} \end{aligned}$$

Como $\{x^k\} \subset D$, que é compacto, segue que $\{x^k\}$ é limitada. Pelo teorema de Bolzano-Weierstrass, possui uma subsequência $\{x^{k_j}\}$ que converge para um ponto $\bar{x} \in D$. Portanto, $\lim_{j \rightarrow \infty} x^{k_j} = \bar{x}$ e pela continuidade de f , se conclui que, $\lim_{j \rightarrow \infty} f(x^{k_j}) = f(\bar{x})$.

Temos também que, $\lim_{j \rightarrow \infty} f(x^{k_j}) = \lim_{k \rightarrow \infty} f(x^k)$, pelo fato da $\{f(x^{k_j})\}$ ser uma subsequência $\{f(x^k)\}$ e que $\{f(x^k)\}$ converge para \bar{v} , logo, temos que:

$$\lim_{j \rightarrow \infty} f(x^{k_j}) = \lim_{k \rightarrow \infty} f(x^k) = f(\bar{x}) = \bar{v}$$

Ou seja, f assume o valor mínimo em \bar{x} . □

Definição 2.3. *O conjunto de nível da função $f : D \rightarrow \mathbb{R}$ associado a $c \in \mathbb{R}$, é o conjunto dado por:*

$$\mathcal{L}f_D(c) = \{x \in D; f(x) \leq c\}$$

Corolário 2.1. *Sejam $D \subset \mathbb{R}^n$ e $f : D \rightarrow \mathbb{R}$ contínua no compacto D . Suponhamos que exista $c \in \mathbb{R}$ tal que $\mathcal{L}f_D(c) \neq \emptyset$*

Demonstração. Pelo teorema de Weierstrass, o problema de $\min f(x)$ sujeito a $x \in \mathcal{L}f_D(c)$ tem solução global, digamos \bar{x} , pelo fato de $\mathcal{L}f_D(c)$ ser um conjunto compacto, ou uma união e compactos. Para todo $x \in D - \{\mathcal{L}f_D(c)\}$, temos $f(x) > c \geq f(\bar{x})$, o que mostra que \bar{x} é um , minimizador global de f e não só de $\mathcal{L}f_D(c)$. □

Definição 2.4. Dizemos que a função $f : D \rightarrow \mathbb{R}$ é coerciva no conjunto D , quando para cada sequência $\{x^k\} \subset D$ tal que ou $\|x^k\| \rightarrow \infty$ ou $\{x^k\} \rightarrow x \in clD \setminus D$ quando $k \rightarrow \infty$ tem-se que $\lim_{k \rightarrow \infty} f(x^k) = +\infty$

- Quando o conjunto D é fechado, mas ilimitado, coercividade de f em D significa que $x^k \in D$ e $\|x^k\| \rightarrow \infty$ implicam $\lim_{k \rightarrow \infty} f(x^k) = +\infty$.
- Quando D é limitado, mas não fechado, coercividade de f em D significa que $x^k \in D$ e $\{x^k\} \rightarrow x \in clD \setminus D$ tem-se $\lim_{k \rightarrow \infty} f(x^k) = +\infty$.
- Quando D é compacto não a sequências em D como a propriedades necessárias.

Exemplo 2.2. Seja $f : D \rightarrow \mathbb{R}, x = (x_1, x_2) \mapsto f(x) = x_1^2 + x_2 + 1/x_1 + x_2$, onde $D = \{x \in \mathbb{R}^2; x_1 + x_2 > 0\}$

- D é ilimitado.
- Ao tomar uma sequência $\{x^k\} \in D$ de modo que $\|x^k\| \rightarrow \infty$, temos $\sqrt{x_{k1}^2 + x_{k2}^2} \rightarrow \infty$
- Ou seja, $x_{k1} \rightarrow \infty$ ou $x_{k2} \rightarrow \infty$
- Portanto $f(x^k) = x_{k1}^2 + x_{k2} + \frac{1}{x_{k1} + x_{k2}} \rightarrow \infty$

Corolário 2.2. Sejam $D \subset \mathbb{R}^n$ e $f : D \rightarrow \mathbb{R}$ uma função contínua coerciva em $D \neq \emptyset$. Então o problema de minimizar f em D possui uma solução global

Demonstração. Definimos $c = f(x)$, com qualquer $x \in D$. Com isso, o conjunto $\mathcal{L}f_D(c)$ é não vazio. Provaremos que ele é compacto.

Suponha que $\mathcal{L}f_D(c)$ seja ilimitada. Então existe uma sequência $\{x^k\} \subset \mathcal{L}f_D(c)$ tal que $\|x^k\| \rightarrow \infty$. Por outro lado, $f(x^k) \leq c$ para todo $k \in \mathbb{N}$ pela definição de conjunto de nível, essa contradição implica que C é limitada

Suponhamos que $\mathcal{L}f_D(c)$ não seja fechado, mas limitado. Então existe $\{x^k\} \subset \mathcal{L}f_D(c)$ tal que $\{x^k\} \rightarrow x \in cl\mathcal{L}f_D(c) \setminus \mathcal{L}f_D(c)$.

Como $\mathcal{L}f_D(c) = \{x \in D; f(x) \leq c\}$ e $\{x^k\} \subset \mathcal{L}f_D(c)$, converge para $x \in cl\mathcal{L}f_D(c) \setminus \mathcal{L}f_D(c)$, pela coercividade de f em D , temos que $\lim_{k \rightarrow \infty} f(x^k) = +\infty$. o que contradiz o fato de que $f(x) \leq c$

Concluimos que $\mathcal{L}f_D(c)$ é não vazio e compacto, logo possui um minimizador global \square

3 Condições de Otimalidade

Quando $D = \mathbb{R}^n$, dizemos que o problema de minimização é irrestrito, e quando $D \neq \mathbb{R}^n$, falamos de problemas com restrições.

- Condições de otimalidade para o problema de minimização irrestrito:

$$\text{minimizar } f(x), \text{ sujeito a } x \in \mathbb{R}^n$$

- Para um problema de minimização restrita, temos

$$\text{minimizar } f(x), \text{ sujeito a } x \in D$$

Onde $D \subset \mathbb{R}^n$, e $\bar{x} \in \text{int}D$

Teorema 3.1. *Condições de otimalidade no caso irrestrito*

- (a) *Suponhamos que $f : \mathbb{R}^n \rightarrow \mathbb{R}$ seja diferenciável no ponto $\bar{x} \in \mathbb{R}^n$. Suponhamos também que \bar{x} seja um minimizador local do problema. Então temos:*

$$f'(\bar{x}) = 0 \tag{1.5}$$

- (b) *Se f é duas vezes diferenciável em \bar{x} , então, além de (1.5), tem-se que a matriz hessiana é semidefinida positiva, isto é:*

$$\langle f''(\bar{x})d, d \rangle \geq 0 \quad \forall d \in \mathbb{R}^n \tag{1.6}$$

- (c) *Suponhamos que $f : \mathbb{R}^n \rightarrow \mathbb{R}$ seja duas vezes diferenciável no ponto $\bar{x} \in \mathbb{R}^n$. Se \bar{x} satisfaz (1.5) e se a matriz hessiana de f em \bar{x} é definida positiva, isto é, se existe $\gamma > 0$ tal que:*

$$\langle f''(\bar{x})d, d \rangle > 0, \quad \forall d \in \mathbb{R}^n \setminus \{0\} \tag{1.7}$$

então f satisfaz em torno de \bar{x} a condição de crescimento quadrático: existem uma vizinhança U de \bar{x} e um número $\beta > 0$ tais que

$$f(x) - f(\bar{x}) \geq \beta \|x - \bar{x}\|^2, \quad \forall x \in U \quad (1.8)$$

Em particular, \bar{x} é minimizador local estrito do problema. Reciprocamente, se vale (1.8), então \bar{x} satisfaz as condições (1.5) e (1.6)

Demonstração. (a): Seja $d \in \mathbb{R}^n$ um vetor arbitrário, porém fixo. Pela definição de minimizador local, existe $\epsilon > 0$ tal que:

$$f(\bar{x}) \leq f(\bar{x} + td), \quad \forall t \in (0, \epsilon).$$

Como f é diferenciável em \bar{x} , podemos usar a expansão de Taylor para obter:

$$f(\bar{x} + td) = f(\bar{x}) + t\langle f'(\bar{x}), d \rangle + o(t).$$

Substituindo na desigualdade, obtemos:

$$f(\bar{x}) \leq f(\bar{x}) + t\langle f'(\bar{x}), d \rangle + o(t).$$

Cancelando $f(\bar{x})$ de ambos os lados, temos:

$$0 \leq t\langle f'(\bar{x}), d \rangle + o(t).$$

Dividindo ambos os lados por t e tomando o limite quando $t \rightarrow 0^+$, obtemos:

$$0 \leq \langle f'(\bar{x}), d \rangle.$$

Como $d \in \mathbb{R}^n$ é arbitrário, escolhemos $d = -f'(\bar{x})$. Assim, temos:

$$0 \leq \langle f'(\bar{x}), -f'(\bar{x}) \rangle = -\|f'(\bar{x})\|^2.$$

Como $-\|f'(\bar{x})\|^2 \leq 0$, isso implica que:

$$\|f'(\bar{x})\|^2 = 0.$$

Logo, concluímos que:

$$f'(\bar{x}) = 0.$$

(b): Seja $d \in \mathbb{R}^n$ arbitrário, porém fixo. Se \bar{x} é minimizador local do problema, então, para todo $t > 0$ suficientemente pequeno, temos:

$$0 \leq f(\bar{x} + td) - f(\bar{x}).$$

Pela expansão de Taylor de segunda ordem, temos:

$$f(\bar{x} + td) = f(\bar{x}) + t\langle f'(\bar{x}), d \rangle + \frac{t^2}{2}\langle f''(\bar{x})d, d \rangle + o(t^2).$$

Subtraindo $f(\bar{x})$ de ambos os lados, obtemos:

$$f(\bar{x} + td) - f(\bar{x}) = t\langle f'(\bar{x}), d \rangle + \frac{t^2}{2}\langle f''(\bar{x})d, d \rangle + o(t^2).$$

Pelo resultado anterior, sabemos que $\langle f'(\bar{x}), d \rangle = 0$. Portanto:

$$0 \leq f(\bar{x} + td) - f(\bar{x}) = \frac{t^2}{2}\langle f''(\bar{x})d, d \rangle + o(t^2).$$

Dividindo ambos os lados por t^2 e tomando o limite quando $t \rightarrow 0^+$, obtemos:

$$0 \leq \frac{1}{2}\langle f''(\bar{x})d, d \rangle.$$

Logo, concluímos que:

$$\langle f''(\bar{x})d, d \rangle \geq 0.$$

(c): Suponhamos que as condições (1.5) e (1.7) sejam válidas, mas que (1.8) não se verifique. Então, existe uma sequência $\{x^k\} \subset \mathbb{R}^n \setminus \{\bar{x}\}$ tal que $\{x^k\} \rightarrow \bar{x}$ e

$$f(x^k) - f(\bar{x}) < \frac{1}{k}\|x^k - \bar{x}\|^2, \quad \forall k.$$

Como a sequência $\{(x^k - \bar{x})/\|x^k - \bar{x}\|\}$ é limitada ($\frac{b}{\|b\|} \Rightarrow \|\frac{b}{\|b\|}\| = 1$), pelo Teorema de Bolzano-Weierstrass, possui pontos de acumulação. Escolhendo uma subsequência conveniente, podemos admitir que $\{(x^k - \bar{x})/\|x^k - \bar{x}\|\} \rightarrow d \in \mathbb{R}^n \setminus \{0\}$.

Assim, temos:

$$\begin{aligned}
\frac{1}{k} \|x^k - \bar{x}\|^2 &> f(x^k) - f(\bar{x}) \\
&= \langle f'(x^k), x^k - \bar{x} \rangle + \frac{1}{2} \langle f''(\bar{x})(x^k - \bar{x}), x^k - \bar{x} \rangle + o(\|x^k - \bar{x}\|^2) \\
&= \frac{1}{2} \langle f''(\bar{x})(x^k - \bar{x}), x^k - \bar{x} \rangle + o(\|x^k - \bar{x}\|^2).
\end{aligned}$$

Dividindo ambos os lados por $\|x^k - \bar{x}\|^2 > 0$ e tomando o limite quando $k \rightarrow \infty$, obtemos

$$0 \geq \langle f''(\bar{x})d, d \rangle,$$

o que contradiz a condição (1.7).

Agora, suponha que a condição de crescimento quadrático (1.8) seja válida. Como ela implica que \bar{x} é um minimizador, obtemos também (1.5).

Seja $d \in \mathbb{R}^n$ um vetor arbitrário, mas fixo. Para todo $t \in \mathbb{R}$ suficientemente pequeno, temos $\bar{x} + td \in U$. Utilizando (1.8) e (1.5), obtemos:

$$\begin{aligned}
\beta t^2 \|d\|^2 &= \beta \|td\|^2 \\
&= \beta \|(\bar{x} + td) - \bar{x}\|^2 \\
&\leq f(\bar{x} + td) - f(\bar{x}) \\
&= t \langle f'(\bar{x}), d \rangle + \frac{t^2}{2} \langle f''(\bar{x})d, d \rangle + o(t^2) \\
&= \frac{t^2}{2} \langle f''(\bar{x})d, d \rangle + o(t^2).
\end{aligned}$$

Dividindo por $t^2 > 0$ e tomando o limite quando $t \rightarrow 0$, obtemos:

$$\beta \|d\|^2 \leq \frac{1}{2} \langle f''(\bar{x})d, d \rangle.$$

Como $d \in \mathbb{R}^n$ é arbitrário, concluímos que $f''(\bar{x})$ é definida positiva.

□

Observação: Note que (1.5) e (1.6) não são suficientes para que um ponto \bar{x} seja minimizador. Um contra exemplo, é a função dada por $f : \mathbb{R} \rightarrow \mathbb{R}$, $f(x) = x^3$, que satisfaz essas condições no ponto \bar{x} , mas não é o minimizador local da função.

4 Convexidade

Definição 4.1. Um conjunto $D \subset \mathbb{R}^n$ é chamado conjunto convexo se para quaisquer $x, y \in D$ e $\alpha \in [0, 1]$, tem-se que $\alpha x + (1 - \alpha)y \in D$

Uma projeção (Ortogonal) do ponto $x \in \mathbb{R}^n$ sobre um conjunto $D \subset \mathbb{R}^n$ é um ponto de D que está mais próximo de x . Em outras palavras, uma solução (global) do problema

$$\text{Min } \|x - y\| \text{ Sujeito a } y \in D \quad (3)$$

Teorema 4.1. Teorema da Projeção

- (a) Seja $D \subset \mathbb{R}^n$ um conjunto fechado. Então, $\forall x \in \mathbb{R}^n$, uma projeção de x sobre D existe.
- (b) Se, além de fechado, D é convexo, então $\forall x \in \mathbb{R}^n$, a projeção de x sobre D , denotada por $P_D(x)$, é única. Além disso, $\bar{x} = P_D(x)$ se, e somente se,

$$\bar{x} \in D, \quad \langle x - \bar{x}, y - \bar{x} \rangle \leq 0, \quad \forall y \in D. \quad (4)$$

- (c) Também tem-se que o operador projeção é monótono e não-expansivo (Lipschitz-contínuo com $L = 1$), ou seja

$$\begin{aligned} \langle x - y, P_D(x) - P_D(y) \rangle &\geq \|P_D(x) - P_D(y)\|^2 \geq 0 \\ \|P_D(x) - P_D(y)\| &\leq \|x - y\|, \quad \forall x, y \in \mathbb{R}^n. \end{aligned}$$

Demonstração. **(a):** Fixemos $y \in \mathbb{R}^n$ arbitrário. Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}_+$, $f(x) = \|x - y\|$. Por ser norma, f é uma função contínua e

$$\mathcal{L}f_D(c) = D \cap B(y, c)$$

Onde

$$B(y, c) = \{x \in \mathbb{R}^n; \|x - y\| < c\} = \{x \in \mathbb{R}^n; f(x) < c\}$$

O conjunto de nível $\mathcal{L}f_D(c)$ é a intersecção do conjunto fechado D com o conjunto compacto $B(y, c)$. Por tanto $\mathcal{L}f_D(c)$ é compacto. Além disso para $c > 0$ suficientemente grande, $B(y, c)$ contém pontos de D . Logo $\mathcal{L}f_D(c) \neq \emptyset$. A afirmação segue pelo corolário 2

(b): Sejam \bar{x} solução do problema e $y \in D$ qualquer. Como $\bar{x} \in D$ e D é convexo, $(1 - \alpha)\bar{x} + \alpha y = x(\alpha) \in D, \forall \alpha \in (0, 1]$. Temos então que $\|x - \bar{x}\| \leq \|x - x(\alpha)\|$, pois \bar{x} é minimizador,

Portanto

$$\begin{aligned}
\|x - \bar{x}\| \leq \|x - x(\alpha)\| &\Rightarrow \|x - \bar{x}\|^2 \leq \|x - x(\alpha)\|^2 \\
0 &\geq \|x - \bar{x}\|^2 - \|x - x(\alpha)\|^2 \\
&= \|x - \bar{x}\|^2 - \|x - \bar{x} + \bar{x} - x(\alpha)\|^2 \\
&= \|x - \bar{x}\|^2 - \|(x - \bar{x}) - (x(\alpha) - \bar{x})\|^2 \\
&= \|x - \bar{x}\|^2 - (\|x - \bar{x}\|^2 - 2\langle x - \bar{x}, x(\alpha) - \bar{x} \rangle + \|x(\alpha) - \bar{x}\|^2) \\
&= 2\langle x - \bar{x}, x(\alpha) - \bar{x} \rangle - \|x(\alpha) - \bar{x}\|^2
\end{aligned}$$

Como

$$x(\alpha) = (1 - \alpha)\bar{x} + \alpha y = \bar{x} - \alpha\bar{x} + \alpha y \Rightarrow x(\alpha) - \bar{x} = \alpha(y - \bar{x})$$

Temos assim que

$$\begin{aligned}
0 &\geq 2\langle x - \bar{x}, \alpha(y - \bar{x}) \rangle - \|\alpha(y - \bar{x})\|^2 \\
&= 2\alpha\langle x - \bar{x}, y - \bar{x} \rangle - \alpha^2\|y - \bar{x}\|^2
\end{aligned}$$

Dividindo Por 2α em ambos os lados, e passando o limite quan $\alpha \rightarrow 0$, se conclui

$$0 \geq \langle x - \bar{x}, y - \bar{x} \rangle$$

Sendo $y \in D$ arbitrário.

Suponhamos agora que um certo \bar{x} satisfaça (2). Então para todo $y \in \mathbb{R}$.

$$\begin{aligned}
0 &\geq \langle x - \bar{x}, y - \bar{x} \rangle \\
&= \langle x, y \rangle + \langle x, -\bar{x} \rangle + \langle -\bar{x}, y \rangle + \langle -\bar{x}, -\bar{x} \rangle \\
&= \frac{1}{2} \left(2\langle x, y \rangle + 2\langle x, -\bar{x} \rangle + 2\langle -\bar{x}, y \rangle + 2\langle -\bar{x}, -\bar{x} \rangle \right) \\
&= \frac{1}{2} \left(2\langle x, y \rangle + 2\langle -\bar{x}, x \rangle + 2\langle -\bar{x}, y \rangle + 2\langle -\bar{x}, -\bar{x} \rangle + \langle x, x \rangle - \langle x, x \rangle + \langle y, y \rangle - \langle y, y \rangle \right) \\
&= \frac{1}{2} \left((\langle x, x \rangle + 2\langle -\bar{x}, x \rangle + \langle -\bar{x}, -\bar{x} \rangle) + (\langle y, y \rangle + 2\langle y, -\bar{x} \rangle + \langle -\bar{x}, -\bar{x} \rangle) - (\langle x, x \rangle + 2\langle x, y \rangle + \langle y, y \rangle) \right) \\
&= \frac{1}{2} \left(\|x - \bar{x}\|^2 + \|y - \bar{x}\|^2 - \|x - y\|^2 \right) \\
&\geq \frac{1}{2} \left(\|x - \bar{x}\|^2 - \|x - y\|^2 \right).
\end{aligned}$$

Concluindo assim, temos

$$\begin{aligned}
0 &\geq \|x - \bar{x}\|^2 - \|x - y\|^2 \\
\|x - y\|^2 &\geq \|x - \bar{x}\|^2 \\
\|x - y\| &\geq \|x - \bar{x}\|
\end{aligned}$$

Temos então, $\|x - \bar{x}\| \leq \|x - y\|, \forall y \in D$, isto é, \bar{x} é uma projeção de x sobre D .

Finalmente, mostrando que a projeção é única. Seja x' alguma outra solução do problema.

Usando (3) para \bar{x} com $y = x' \in D$, temos

$$\begin{aligned}
0 &\geq \langle x - \bar{x}, x' - \bar{x} \rangle + \langle x - x', \bar{x} - x' \rangle \\
&= \langle x - \bar{x}, x' - \bar{x} \rangle - \langle x - x', x' - \bar{x} \rangle \\
&= \langle x - \bar{x} - (x - x'), x' - \bar{x} \rangle \\
&= \langle x' - \bar{x}, x' - \bar{x} \rangle \\
&= \|x' - \bar{x}\|^2
\end{aligned}$$

Temos assim $0 \geq \|x' - \bar{x}\| \geq 0$, que implica $x' = \bar{x}$. Logo a projeção é única.

(c): Provando agora que o operador projeção é monótono e não-exansivo.

Como $P_D(x)$ e $P_D(y) \in D$, Usando (3) duas vezes (para x e y), obtemos:

$$\begin{aligned}\langle x - P_D(x), P_D(y) - P_D(x) \rangle &\leq 0 \\ \langle y - P_D(y), P_D(x) - P_D(y) \rangle &\leq 0\end{aligned}$$

Somando as duas desigualdades temos:

$$\begin{aligned}0 &\geq \langle x - P_D(x), P_D(y) - P_D(x) \rangle + \langle y - P_D(y), P_D(x) - P_D(y) \rangle \\ &= \langle P_D(x) - x, P_D(x) - P_D(y) \rangle + \langle y - P_D(y), P_D(x) - P_D(y) \rangle \\ &= \langle P_D(x) - x + y - P_D(y), P_D(x) - P_D(y) \rangle \\ &= \langle [P_D(x) - P_D(y)] + y - x, P_D(x) - P_D(y) \rangle \\ &= \langle P_D(x) - P_D(y), P_D(x) - P_D(y) \rangle + \langle y - x, P_D(x) - P_D(y) \rangle \\ &= \|P_D(x) - P_D(y)\|^2 - \langle x - y, P_D(x) - P_D(y) \rangle\end{aligned}$$

Portanto

$$\langle x - y, P_D(x) - P_D(y) \rangle \geq \|P_D(x) - P_D(y)\|^2 \geq 0$$

O que prova a primeira afirmação

Provando que o operador projeção é não expansivo. Basta notar que por Cauchy-Schwarz temos:

$$\begin{aligned}\|P_D(x) - P_D(y)\| \cdot \|x - y\| &\geq |\langle P_D(x) - P_D(y), y - x \rangle| \\ &= |-\langle x - y, P_D(x) - P_D(y) \rangle| \\ &= \langle x - y, P_D(x) - P_D(y) \rangle \geq \|P_D(x) - P_D(y)\|^2\end{aligned}$$

Se $P_D(x) = P_D(y)$, vale igualdade, do contrário, temos

$$\langle x - y, P_D(x) - P_D(y) \rangle \geq \|P_D(x) - P_D(y)\|^2$$

e dividindo por $\|P_D(x) - P_D(y)\|^2$ em ambos os lados temos

$$\|y - x\| = \|x - y\| \geq \|P_D(x) - P_D(y)\|$$

□

Definição 4.2. *Seja $D \subset \mathbb{R}^n$ um conjunto convexo. Diz-se que a função $f : D \rightarrow \mathbb{R}^n$ é*

convexa em D quando para quaisquer $x, y \in D$ e $\alpha \in [0, 1]$ tem-se:

$$f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y)$$

- A função f diz-se estritamente convexa quando a desigualdade acima é estrita
- A função f diz-se fortemente convexa com $\gamma > 0$, quando para quaisquer $x, y \in D$ e $\alpha \in [0, 1]$, tem-se que

$$f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y) - \gamma\alpha(1 - \alpha)\|x - y\|^2$$

- Uma função fortemente convexa é estritamente convexa
- Uma função estritamente convexa é convexa

Exemplo 4.1. A função $f : \mathbb{R} \rightarrow \mathbb{R}$, $f(x) = x^2$ é fortemente convexa:

Demonstração.

$$\begin{aligned} f(\alpha x + (1 - \alpha)y) &= \alpha^2 x^2 + y^2(1 - 2\alpha + \alpha^2) + 2xy\alpha(1 - \alpha) \\ &= \alpha^2 x^2 + y^2 - 2y^2\alpha + y^2\alpha^2 + 2xy\alpha(1 - \alpha) \\ &= \alpha^2 x^2 + y^2(1 - \alpha) - y^2\alpha + y^2\alpha^2 + 2xy\alpha(1 - \alpha) \\ &= \alpha^2 x^2 + y^2(1 - \alpha) + y^2(-\alpha) + y^2\alpha^2 + 2xy\alpha(1 - \alpha) \\ &= \alpha^2 x^2 + y^2(1 - \alpha) + y^2(-\alpha) + y^2\alpha^2 + 2xy\alpha(1 - \alpha) \\ &= \alpha^2 x^2 + y^2(1 - \alpha) - \alpha(1 - \alpha)y^2 + 2xy\alpha(1 - \alpha) \\ &= \alpha^2 x^2 + y^2(1 - \alpha) - \alpha(1 - \alpha)(y^2 - 2xy) \end{aligned}$$

Note agora que como

$$(x - y)^2 = (y^2 - 2xy + x^2) \geq y^2 - 2xy$$

Tomando agora $\gamma > 0$ suficientemente pequeno, temos

$$\begin{aligned} f(\alpha x + (1 - \alpha)y) &= \alpha^2 x^2 + y^2(1 - \alpha) - \alpha(1 - \alpha)(y^2 - 2xy) \\ &= \alpha^2 f(x) + (1 - \alpha)f(y) - \alpha(1 - \alpha)(y^2 - 2xy) \\ &\leq \alpha^2 f(x) + (1 - \alpha)f(y) - \gamma\alpha(1 - \alpha)(x - y)^2 \end{aligned}$$

Logo f é fortemente convexa

□

Definição 4.3. Dizemos que

$$\min f(x) \text{ sujeito a } x \in D$$

é um problema de minimização convexa quando $D \subset \mathbb{R}^n$ é um conjunto convexo e $f : D \rightarrow \mathbb{R}$ é uma função convexa no conjunto D

Teorema 4.2. *Minimização convexa* Sejam $D \subset \mathbb{R}^n$ um conjunto convexo e $f : D \rightarrow \mathbb{R}^n$ uma função convexa em D . Então todo minimizador local do problema é também um minimizador global. Além disso, o conjunto de minimizadores é convexo. Se f é estritamente convexa, não pode haver mais de um minimizador.

Demonstração. Suponhamos que $\bar{x} \in D$ seja um minimizador local que não é global. Então existe $y \in DX$ tal que $f(y) < f(\bar{x})$. Definindo $x(\alpha) = \alpha y + (1 - \alpha)\bar{x}$. Pela convexidade de D , $x(\alpha) \in D, \forall \alpha \in [0, 1]$. Agora pela convexidade de f , para todo α , tem-se

$$\begin{aligned} f(x(\alpha)) &= f(\alpha y + (1 - \alpha)\bar{x}) \\ &\leq \alpha f(y) + (1 - \alpha)f(\bar{x}) \\ &= \alpha f(y) + f(\bar{x}) - \alpha f(\bar{x}) \\ &= f(\bar{x}) + \alpha(f(y) - f(\bar{x})) \\ &< f(\bar{x}) \end{aligned}$$

Portanto

$$f(x(\alpha)) \leq f(\bar{x}) + \alpha(f(y) - f(\bar{x})) < f(\bar{x})$$

Tomando $\alpha > 0$ suficientemente pequeno, podemos garantir ue o ponto $x(\alpha)$ é arbitrariamente próximo a \bar{x} , e ainda temos que $f(x(\alpha)) < f(\bar{x})$ e \bar{x} é minimizador local do problema. Absurdo, pois assim \bar{x} não é minimizador local don problema. Logo qualquer solução local do problema é também uma solução global.

Seja agora $S \subset D$ o conjunto dos minimizadores (globais) e $\bar{v} \in \mathbb{R}$ o valor ótimo do problema ($f(x) = \bar{v}, \forall x \in S$). Para quaisquer $x, \bar{x} \in S$ e $\alpha \in [0, 1]$, pela convexidade de f , obtemos

$$\begin{aligned} f(\alpha x + (1 - \alpha)\bar{x}) &\leq \alpha f(x) + (1 - \alpha)f(\bar{x}) \\ &= \alpha \bar{v} + \bar{v} - \alpha \bar{v} = \bar{v} \end{aligned}$$

Como também $\alpha x + (1 - \alpha)\bar{x} \in D$, concluímos que $f(\alpha x + (1 - \alpha)\bar{x} = \bar{v})$, isto é, $\alpha x + (1 - \alpha)\bar{x} \in S$, ou seja, S é convexo.

Suponhamos agora que f seja estritamente convexa e que existem $x, \bar{x} \in S$ com $x \neq \bar{x}$. Pela convexidade estrita de f tem-se que

$$f(\alpha x + (1 - \alpha)\bar{x}) < \alpha f(x) + (1 - \alpha)f(\bar{x}) = \bar{v}$$

Como o conjunto S é convexo, temos então, uma solução do problema $\alpha x + (1 - \alpha)\bar{x}$, portanto:

$$f(\alpha x + (1 - \alpha)\bar{x}) < \bar{v} \tag{5}$$

Temos assim que o valor da função objetivo menor que o valor ótimo do problema \bar{v} , que é uma contradição. Logo o minimizador é único.

Definição 4.4. *Se $D \subset \mathbb{R}^n$ é um conjunto convexo, dizemos que $f : D \rightarrow \mathbb{R}$ é uma função côncava em D , quando a função $-f$ é convexa em D*

Teorema 4.3. *Continuidade de funções convexas Sejam $\Omega \subset \mathbb{R}^n$ um conjunto convexo e aberto, e $f : \Omega \rightarrow \mathbb{R}$ uma função convexa em Ω . Então f é Lipschitz-Contínua em Ω . Em particular f é contínua*

□

5 Classificação dos métodos e noções de convergência

Seja o problema de:

$$\min f(x) \quad \text{sujeito a} \quad x \in D$$

Onde $D \in \mathbb{R}^n$.

Todo método para resolução numérica do problema faz uso de cálculos dos valores da função, das restrições e de suas derivadas.

- **Método Passivo:** Quando os pontos de avaliação destes valores são escolhidos de acordo com uma estratégia definida a priori, sem levar em conta as informações obtida ao longo do processo iterativo
- **Método Sequencial:** Cada ponto é definido de acordo com a informação obtida nos pontos anteriores. Um método sequencial gera uma sequência de pontos no \mathbb{R}^n , como $x^1, x^2, \dots, x^k, \dots$, que serão chamados de aproximações à solução do problema.

Com frequência, algoritmos são descritos em formato de um esquema iterativo, como:

$$x^{k+1} = \Psi_k(x^k), \quad k = 0, 1, \dots$$

Onde Ψ_k é um operador cujos valores estão contidos em \mathbb{R}^n .

Naturalmente, supomos que na iteração $k + 1$, Ψ_k seja conhecida. Se o esquema iterativo for fixado, a escolha do ponto inicial x^0 define uma trajetória do método se, e somente se,

$$\Psi_{k-1}(\Psi_{k-2}(\dots(\Psi_0(x^0))\dots)).$$

Algumas nomenclaturas importantes:

- **Ordem:** A ordem do método é a máxima ordem das derivadas da função objetivo e das restrições que estão sendo utilizadas.
- **Métodos com Convergência Assintótica:** Não há garantia de que algum x^k da trajetória seja uma solução do problema. A tarefa é provar que, para algum k suficientemente grande, x^k é uma boa aproximação da solução do problema.

5.1 Tipos de Convergência

- (1) Se $\{x^k\} \rightarrow \bar{x}$, onde \bar{x} é uma solução do problema, falamos de **convergência em relação às variáveis do problema** a partir de x^0 .
- (2) Quando não é possível provar convergência a uma solução específica, mas apenas garantir que $\text{Dist.}(x^k, S) \rightarrow 0$, onde S é o conjunto de soluções do problema, falamos de **convergência ao conjunto de soluções**.
- (3) Se $\text{Dist.}(x^k, D) \rightarrow 0$ e $f(x^k) \rightarrow \bar{v}$, falamos de **convergência em relação à função objetivo**.
- (4) No caso de problemas irrestritos, se $\{f'(x^k)\} \rightarrow 0$, falamos de **convergência em relação ao gradiente**.
- (5) Quando $U_0 = \mathbb{R}^n$ e há convergência a partir de qualquer ponto $x^0 \in \mathbb{R}^n$, falamos de **convergência global**.
- (6) Se algum tipo de convergência é garantido apenas para pontos suficientemente próximos à solução do problema, falamos de **convergência local do método**.

5.2 Taxas de convergência. Regras de parada

Suponhamos que um método dado seja convergente a uma solução \bar{x} , isto é, $\{x^k\} \rightarrow \bar{x} (k \rightarrow \infty)$. Resultados sobre a taxa de convergência fornecem uma garantia de velocidade na redução da distância $\|x^{k+1} - \bar{x}\|$ em relação a $\|x^k - \bar{x}\|$, quando k é suficientemente grande.

- (1) Supomos que $x^0 \in \mathbb{R}^n$ é suficientemente próximo de \bar{x} , que $x^k \neq \bar{x} \forall k \in \mathbb{N}$, e que todos os números constantes mencionados a seguir não dependem de x^0 . Se existe $q \in (0, 1)$ tal que:

$$\limsup_{k \rightarrow \infty} \frac{\|x^{k+1} - \bar{x}\|}{\|x^k - \bar{x}\|} = q,$$

dizemos que o método possui **convergência linear**

- (2) Convergência mais lenta que a linear é chamada de **Sublinear**
- (3) Um exemplo que garante apenas taxa sublinear é a seguinte

$$\limsup_{k \rightarrow \infty} k \|x^k - \bar{x}\| \leq C,$$

Onde $C > 0$ é uma constante. Neste caso falamos de **Convergência Aritmética**

- (4) Quando:

$$\limsup_{k \rightarrow \infty} \frac{\|x^k - \bar{x}\|}{q^k} \leq C$$

Onde $q \in (0, 1)$, falamos de **Convergência Geométrica**.

- (5) Quando

$$\limsup_{k \rightarrow \infty} \frac{\|x^k - \bar{x}\|}{\|x^k - \bar{x}\|} = 0$$

falamos de **Convergência Superlinear**

- (6) Um caso especial de convergência superlinear é a **Convergência quadrática**

$$\limsup_{k \rightarrow \infty} \frac{\|x^k - \bar{x}\|}{\|x^k - \bar{x}\|^2} \leq C$$

Temos também que a convergência quadrática é mais rápida que a convergência superlinear que é mais rápida que a convergência linear

6 Otimização irrestrita

6.1 Métodos de descida

Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função dada. Uma das estratégias para resolver o problema irrestrito

$$\min f(x), x \in \mathbb{R}^n \quad (6)$$

é o seguinte, dada uma aproximação $x^k \in \mathbb{R}^n$ da solução do problema, encontramos um ponto $x^{k+1} \in \mathbb{R}^n$ tal que

$$f(x^{k+1}) < f(x^k)$$

Uma estratégia básica para isso é tomar uma direção $d^k \in \mathbb{R}^n$ tal que f é decrescente, e computar um comprimento de passo $\alpha_k > 0$ que fornece um valor de f menor que o ponto x^k , isto é,

$$f(x^k + \alpha_k d^k) < f(x^k)$$

Assim obtento o ponto $x^{k+1} = x^k + \alpha_k d^k$. Repetindo o processo, tomando $x^k = x^{k+1}$, construímos o esquema iterativo dos métodos de descida.

6.2 Esquema geral dos métodos de descida

Definição 6.1. Dizemos que $d \in \mathbb{R}^n$ é uma direção de descida da função $f : \mathbb{R}^n \rightarrow \mathbb{R}$ no ponto $x \in \mathbb{R}^n$, se existe $\epsilon > 0$ tal que

$$f(x + td) < f(x), \forall t \in (0, \epsilon]$$

Denotamos por $\mathcal{D}_f(x)$ o conjunto de todas as direções de descidas da função f no ponto x

Lema 6.1. (Direções de descidas): Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável no ponto $x \in \mathbb{R}^n$. Então:

(a) Para todo $d \in \mathcal{D}_f(x)$, tem-se $\langle f'(x), d \rangle \leq 0$

(b) Se $d \in \mathbb{R}^n$ satisfaz $\langle f'(x), d \rangle < 0$, tem-se $d \in \mathcal{D}_f(x)$

Demonstração. Seja $d \in \mathcal{D}_f(x)$. Para todo $t > 0$ suficientemente pequeno, pela diferenciabilidade de f em x , temos:

$$\begin{aligned} -f(x + td) &= f(x) + \langle f'(x), td \rangle + o(t) \\ &= f(x) + t \left(\langle f'(x), d \rangle + \frac{o(t)}{t} \right). \end{aligned}$$

Pelo fato de d ser uma direção de descida, segue que

$$0 \geq f(x + td) - f(x) = t \left(\langle f'(x), d \rangle + \frac{o(t)}{t} \right).$$

Portanto:

$$0 \geq t \left(\langle f'(x), d \rangle + \frac{o(t)}{t} \right).$$

Dividindo por t e passando ao limite quando $t \rightarrow 0$, concluímos que:

$$0 \geq \langle f'(x), d \rangle.$$

o que prova o ítem (a)

Suponha agora que $\langle f'(x), d \rangle < 0$. Temos que:

$$f(x + td) - f(x) = t \left(\langle f'(x), d \rangle + \frac{o(t)}{t} \right).$$

Note que para $t > 0$ suficientemente pequeno, vale:

$$\langle f'(x), d \rangle + \frac{o(t)}{t} \leq \langle f'(x), d \rangle < 0,$$

Já que $\frac{o(t)}{t} \rightarrow 0$ e $\langle f'(x), d \rangle < 0$. Sendo assim:

$$\begin{aligned} f(x + td) - f(x) &= t \left(\langle f'(x), d \rangle + \frac{o(t)}{t} \right) < 0 \\ &\implies f(x + td) - f(x) < 0 \\ &\implies f(x + td) < f(x). \end{aligned}$$

O que prova o ítem (b)

□

O esquema geral dos métodos de descida consiste no seguinte

$$x^{k+1} = x^k + \alpha_k d^k, d^k \in \mathcal{D}_f(x^k), k = 1, 2, \dots$$

Onde os valores do comprimento de passo $\alpha_k > 0$ são calculados para obter pelo menos a condição de que $f(x^{k+1}) < f(x^k)$, ou seja $\{f(x^k)\}$ é decrescente

Por $d^k \in \mathcal{D}_f(x^k)$, temos que $\alpha_k > 0$ sempre existe, portanto, obtemos um decréscimo dos membros de $\{x^k\}$ quando olhamos para as curvas de nível de f .

6.3 Buscas lineares

Apresentando principais regras de busca linear, supondo um ponto x^k dado e uma direção $d \in \mathcal{D}_f(x)$ já escolhida

6.3.1 Regra de Minimização Unidimensional

O objetivo desta regra é minimizar a função objetivo ao longo da semi-reta $x^k + \alpha d^k$, com $\alpha \geq 0$. Nessa regra, o comprimento de passo α_k é dado pela condição

$$f(x_k + \alpha_k d^k) = \min f(x^k + \alpha d^k)$$

Isto é, α_k é a solução do problema

$$\min \varphi_k(\alpha), \alpha \in \mathbb{R}_+ \tag{7}$$

onde $\varphi_k : \mathbb{R}_+ \rightarrow \mathbb{R}$, $\varphi(\alpha) = f(x^k + \alpha d^k)$.

Note que, para $\alpha > 0$ suficientemente pequeno, temos que $\varphi(0) > \varphi(\alpha)$, pois, como $d^k \in \mathcal{D}_f(x^k)$, segue que $f(x^k) > f(x^k + \alpha d^k)$. Portanto, se α_k é o mínimo de $\varphi(\alpha)$, então $\varphi(\alpha_k) < \varphi(0)$. Assim, temos um problema de minimização unidimensional.

Se f é diferenciável, então $\varphi_k(\alpha)$ também é diferenciável. Com isso, se α_k é o minimizador de $\varphi_k(\alpha)$, segue, por 1.5, que:

$$0 = \varphi'_k(\alpha_k) = \langle f'(x^k + \alpha_k d^k), d^k \rangle = \langle f'(x^{k+1}), d^k \rangle$$

Do ponto de vista geométrico, o gradiente do ponto x^{k+1} é ortogonal à direção d^k , e x^{k+1} é o ponto de interseção da semi-reta a partir de x^k com a curva de nível de f que passa pelo

ponto x^{k+1} . Este valor α_k é o melhor possível no sentido de que, no ponto correspondente, obtemos o menor valor de f entre todos os pontos da forma $x^k + \alpha d^k$.

6.3.2 Regra de Armijo

Enquanto a minimização unidimensional busca encontrar o valor exato do comprimento de passo α_k que minimiza a função objetivo ao longo de uma direção, a Regra de Armijo adota uma abordagem mais flexível. Ela garante que o comprimento de passo escolhido produza uma redução suficiente na função objetivo, evitando tanto passos excessivamente grandes, que podem ultrapassar o mínimo ou aumentar o valor da função, quanto passos muito pequenos, que podem comprometer a eficiência do algoritmo ao torná-lo lento.

Ideia da Regra de Armijo

- Considere o gráfico de $\varphi_k(\alpha) - \varphi_k(0)$
- Note que $\varphi_k(0) - \varphi_k(0) = 0$
- Como $d^k \in \mathcal{D}_f(x^k)$, para $\alpha > 0$ suficientemente pequeno, temos que $\varphi_k(\alpha) - \varphi_k(0) < 0$
- Tome a aproximação linear de $\varphi_k(\alpha) - \varphi_k(0)$ quando $\alpha = 0$ que é dada por $\alpha\varphi'_k(0)$
- Note que, para $\alpha > 0$ suficientemente pequeno temos que $\alpha\varphi'_k(0) < \varphi_k(\alpha) - \varphi_k(0)$
- Tome uma reta, com inclinação negativa, mas acima de $\alpha\varphi'_k(0)$, a partir da mesma
- Seja $\sigma\alpha\varphi'_k(0)$, com $\sigma \in (0, 1)$ essa reta (σ escolhido arbitrariamente)
- Como $\alpha\varphi'_k(0) < 0$ e $\sigma > 0$, segue que $\sigma\alpha\varphi'_k(0) < 0$ (Isso para α suficientemente pequeno)
- Tome um $\hat{\alpha} > 0$, e um parâmetro $\theta \in (0, 1)$ de modo que $\theta\hat{\alpha} < \hat{\alpha}$
- Note que como $\theta^{i_k}\hat{\alpha} \rightarrow 0$, quando $k \rightarrow \infty$ existe $\varphi_k(\theta^{i_k}\hat{\alpha}) - \varphi_k(0) < \sigma\theta^{i_k}\hat{\alpha}\varphi'_k(0)$
- O primeiro $\theta^{i_k}\hat{\alpha}$ que satisfaz a condição acima será escolhido como α_k
- Tomando $\alpha = \theta^{i_k}\hat{\alpha}$ temos que

$$\varphi_k(\alpha) - \varphi(0) = f(x^k + \theta^{i_k}\hat{\alpha}d^k) - f(x^k) = f(x^{k+1}) - f(x^k) < 0$$

Em resumo, a *regra de Armijo* consiste em computar um comprimento de passo que resulta em um decréscimo suficiente da função f em relação ao valor $f(x^k)$, que garanta convergência, isto é

$$f(x^k + \alpha d^k) \leq f(x^k) + \sigma \alpha \langle f'(x^k), d^k \rangle \quad (8)$$

em que f é diferenciável no ponto x^k , $\alpha > 0$ e $\sigma \in (0, 1)$.

O valor $\alpha \langle f'(x^k), d^k \rangle$ representa o valor de redução de f , previsto pela aproximação linear para α na direção d^k

Lema 6.2. (A regra de Armijo está bem definida)

Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável no ponto x^k . Suponhamos que $d^k \in \mathbb{R}^n$ satisfaça $\langle f'(x^k), d^k \rangle < 0$. Então a desigualdade (8) é satisfeita para todo $\alpha > 0$ suficientemente pequeno. Em particular, Armijo está bem definida e termina com $\alpha_k > 0$

Demonstração. Como f é diferenciável, para $\alpha > 0$ suficientemente pequeno, temos

$$\begin{aligned} f(x^k + \alpha d^k) - f(x^k) &= \langle f'(x^k), \alpha d^k \rangle + o(\alpha) \\ &= \alpha \langle f'(x^k), d^k \rangle + \sigma \alpha \langle f'(x^k), d^k \rangle - \sigma \alpha \langle f'(x^k), d^k \rangle + o(\alpha) \\ &= \sigma \alpha \langle f'(x^k), d^k \rangle + (1 - \sigma) \alpha \langle f'(x^k), d^k \rangle + o(\alpha) \\ &= \sigma \alpha \langle f'(x^k), d^k \rangle + \alpha ((1 - \sigma) \langle f'(x^k), d^k \rangle + \frac{o(\alpha)}{\alpha}) \\ &\leq \sigma \alpha \langle f'(x^k), d^k \rangle \end{aligned}$$

Pois

$$(1 - \sigma) \langle f'(x^k), d^k \rangle + \frac{o(\alpha)}{\alpha} \leq \frac{1 - \sigma}{2} \langle f'(x^k), d^k \rangle < 0$$

Que vale para $\alpha > 0$ suficientemente pequeno. Portanto $f(x^k + d^k) - f(x^k) \leq \sigma \alpha \langle f'(x^k), d^k \rangle$, logo vale a desigualdade de armijo. \square

Lema 6.3. (Cota inferior para o comprimento de passo dado por Armijo)

Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável no \mathbb{R}^n , com derivada Lipschitz-contínua no \mathbb{R}^n com módulo $L > 0$. Se $x^k, d^k \in \mathbb{R}^n$ satisfaz 6.1, então a desigualdade (8) é válida para todo $\alpha \in (0, \bar{\alpha}_k)$, onde

$$\bar{\alpha}_k = \frac{2(\sigma - 1) \langle f'(x^k), d^k \rangle}{L \|d^k\|^2}$$

Demonstração. Pelo lema (1), para todo $\alpha \in \mathbb{R}$, tem-se que

$$\begin{aligned} f(x^k + \alpha d^k) - f(x^k) &\leq \langle f'(x^k), \alpha d^k \rangle + \frac{L}{2} \cdot \alpha^2 \|d^k\|^2 \\ &= \alpha (\langle f'(x^k), d^k \rangle + \frac{L}{2} \cdot \alpha \|d^k\|^2) \end{aligned}$$

Logo, para $\alpha \in (0, \bar{\alpha}_k)$, segue

$$\begin{aligned} f(x^k + \alpha d^k) - f(x^k) &= \alpha (\langle f'(x^k), d^k \rangle + \frac{L}{2} \cdot \alpha \|d^k\|^2) \\ &= \alpha (\langle f'(x^k), d^k \rangle + \frac{L}{2} \|d^k\|^2 \cdot \frac{2(\sigma - 1) \langle f'(x^k), d^k \rangle}{L \|d^k\|^2}) \\ &= \alpha (\langle f'(x^k), d^k \rangle + (\sigma - 1) \langle f'(x^k), d^k \rangle) \\ &= \alpha \sigma \langle f'(x^k), d^k \rangle \end{aligned}$$

Onde a última igualdade segue de (6.3) □

Interpretação do lema: No caso em que o gradiente da f é Lipschitz-contínuo, o valor de $f(x^k + \alpha d^k) - f(x^k)$ é menor ou igual a valor da função quadrática $\alpha \langle f'(x^k), d^k \rangle + \alpha^2 \frac{L \|d^k\|^2}{2}$, que é uma aproximação a Taylor de segunda ordem de $\varphi_k(\alpha) - \varphi_k(0)$

Sob as hipóteses do lema anterior, se $\frac{\langle f'(x^k), d^k \rangle}{\|d^k\|^2} \leq \delta < 0$, onde δ é uma constante que não depende de k , e se os parâmetros α^*, σ, θ são os mesmos a cada iteração, segue que (8) é satisfeita para todo $\alpha \in (0, \bar{\alpha})$, onde

$$\bar{\alpha} = \frac{-2\delta(1 - \sigma)}{L} > 0$$

Como um α_k maior não foi aceito, ou $\alpha_k = \alpha^*$, ou então $\frac{\alpha_k}{\theta} > \bar{\alpha}$. Concluimos então que $\alpha_k \geq \min \{\alpha^*, \theta \bar{\alpha}\} = \tilde{\alpha} > 0$

6.3.3 Regra de Goldstein

Nessa regra, o comprimento de passo $\alpha_k > 0$, é calculado para satisfazer às seguintes desigualdades em relação a α

1. $\sigma_1 \alpha \langle f'(x^k), d^k \rangle \leq f(x^k + \alpha d^k) - f(x^k)$
2. $f(x^k + \alpha d^k) - f(x^k) \leq \alpha \sigma_2 \langle f'(x^k), d^k \rangle$ (Armijo)

Onde $0 < \sigma_1 < \sigma_2 < 1$

Note que a primeira desigualdade é facilmente violada para $\alpha > 0$ suficientemente pequeno, por conta disso ela tem como objetivo evitar passos muito curtos que seria aceito pela regra de Armijo. Essas duas desigualdades pode ser escrita da seguinte forma

$$\sigma_1 \leq \frac{f(x^k + \alpha d^k) - f(x^k)}{\alpha \langle f'(x^k), d^k \rangle} \leq \sigma_2 \quad (9)$$

Ou ainda

$$\sigma_1 \alpha \langle f'(x^k), d^k \rangle \leq f(x^k + \alpha d^k) - f(x^k) \leq \sigma_2 \alpha \langle f'(x^k), d^k \rangle$$

Ideia da Regra de Goldstein

- Considere a função $\varphi_k(\alpha) - \varphi_k(0)$, a desigualdade de Armijo e suas conclusões
- Como $0 < \sigma_1 < \sigma_2 < 1$, temos $\sigma_1 \alpha \langle f'(x^k), d^k \rangle > \sigma_2 \alpha \langle f'(x^k), d^k \rangle$, para $\alpha > 0$
- Com isso, existem valores de α_k tal que $\sigma_1 \alpha_k \langle f'(x^k), d^k \rangle \leq f(x^k + \alpha_k d^k) - f(x^k) \leq \sigma_2 \alpha_k \langle f'(x^k), d^k \rangle$

Tais valores α_k serão aceito.

Teorema 6.1. (A regra de Goldstein está bem definida) *Sejam $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função continuamente diferenciável e limitada inferiormente ao longo do conjunto $\{x^k + \alpha d^k; \alpha > 0\}$ e d^k uma direção de descida a partir de x^k . Se $0 < \sigma_1 < \sigma_2 < 1$, então existe um intervalo de comprimentos de passo que satisfazem simultaneamente as condições de Goldstein.*

Demonstração. Por hipótese, temos que f é contínua e limitada inferiormente, então a restrição de f na direção d_k a partir de x_k dada por $\varphi(\alpha) = f(x_k + \alpha d_k)$ é contínua e limitada inferiormente para todo $\alpha > 0$. Além disso, temos que d_k é direção de descida, ou seja, $\langle f'(x^k), d^k \rangle < 0$, o que nos fornece

$$\lim_{\alpha \rightarrow \infty} l_1(\alpha) = \lim_{\alpha \rightarrow \infty} l_2(\alpha) = -\infty.$$

Note que a função $l_1(\cdot)$ tem a inclinação negativa dada por $\sigma_1 \alpha_k \langle f'(x^k), d^k \rangle$, mas como $\sigma_1 \in (0, 1)$, a reta l_1 fica acima do gráfico de φ para pequenos valores positivos de α (ou para α próximo de 0), e o mesmo ocorre para a reta l_2 . Então, existe α' próximo de zero tal que $\varphi(\alpha') = c' < l_2(\alpha')$.

Por outro lado, pela definição de limite infinito no infinito, temos que, dado $c'' < 0$, existe $N > 0$ tal que $\alpha'' > N$ implica $\varphi(\alpha'') \geq c'' > l_2(\alpha'')$. Pelo Teorema do Valor Intermediário, existe $\alpha''' \in (\alpha', \alpha'')$ tal que $\varphi(\alpha''') = c''' = l_2(\alpha''')$, ou seja, φ intersecta l_2 .

Utilizando um raciocínio análogo, pode-se mostrar que φ também intersecta l_1 . Note também que $\sigma_1 < \sigma_2$, então o coeficiente angular de l_2 é menor do que o coeficiente angular de l_1 , ou seja, l_2 decresce mais rapidamente do que l_1 , o que implica que $l_2(\alpha) < l_1(\alpha)$, para todo $\alpha > 0$.

Disso decorre que $\varphi(\alpha)$ intersecta $l_2(\alpha)$ antes de intersectar $l_1(\alpha)$. Além disso, $\varphi(\alpha)$ intersecta l_1 e l_2 em no máximo um número finito de vezes, já que $\varphi(\alpha)$ é limitada inferiormente, enquanto l_1 e l_2 não são.

Seja α_1 o comprimento do passo que gera a primeira interseção de φ com l_1 e α_2 o maior comprimento de passo menor do que α_1 onde φ intersecta l_2 . O intervalo (α_2, α_1) é formado por comprimentos de passo que satisfazem as condições de Goldstein. O mesmo critério pode ser usado para os outros pontos de interseção de φ com l_1 e l_2 . \square

6.3.4 Regra de Wolfe

Nessa Regra o comprimento de passo $\alpha_k > 0$ é calculado para satisfazer às seguintes desigualdades em relação a α

1. $f(x^k + \alpha d^k) \leq f(x^k) + \sigma_1 \alpha \langle f'(x^k), d^k \rangle$ (Armijo)
2. $\langle f'(x^k + \alpha d^k), d^k \rangle \geq \sigma_2 \langle f'(x^k), d^k \rangle$

Onde $0 < \sigma_1 < \sigma_2 < 1$.

Novamente a primeira desigualdade é a regra de Armijo. Já a segunda serve como controle para a minimização de f ao longo de $x^k + \alpha d^k$, onde $\alpha \geq 0$. Como visto na minimização unidimensional, se $\alpha > 0$ é mínimo de $\varphi(\alpha)$ então $\langle f'(x^k + \alpha d^k), d^k \rangle = 0$. Portanto a segunda desigualdade é um teste de qualidade para um $\alpha > 0$ dado como uma aproximação de minimizadores de f na semi-reta ao longo de d^k . (Isso ocorre pois como $\sigma_2 \langle f'(x^k), d^k \rangle$ e $\langle f'(x^k + \alpha d^k), d^k \rangle$ são negativos, se a desigualdade é satisfeita, a primeira parcela se aproxima de 0)

Então qualquer implementação da regra de Wolfe, para o qual tem-se que $\tilde{\alpha} \rightarrow \infty$ no caso de um número infinito de extrapolações e $(\hat{\alpha} - \tilde{\alpha}) \rightarrow 0$ no caso de um número infinito de interpolações, está bem definida, no sentido de que ela termina com um valor de comprimento de passo $\alpha_k > 0$

7 Método do gradiente

Método do gradiente é um dos métodos de descida que usa a direção do gradiente como direção de descida. Suponhamos que $f : \mathbb{R}^n \rightarrow \mathbb{R}$ seja uma função diferenciável, tomamos como direção de descida $d^k = -f'(x^k)$, note que $\langle f'(x^k), -f'(x^k) \rangle = -\|f'(x^k)\|^2 < 0$, para $f'(x^k) \neq 0$. A iteração no método do gradiente é dada da seguinte forma

$$x^{k+1} = x^k - \alpha_k d^k$$

Analisando no contexto da minimização Uni-dimensional, temos que vale a igualdade

$$\langle f'(x^{k+1}), f'(x^k) \rangle = 0$$

Que é válida para $0 = \varphi'_k(\alpha)$. Ou seja, $d^k = -f'(x^k)$ e $d^{k+1} = -f'(x^{k+1})$, são ortogonais, o que explica a trajetória em "zig - zag" do método do gradiente

No contexto da Regra de Armijo, temos que a desigualdade é da seguinte forma

$$f(x^k - \alpha f'(x^k)) \leq f(x^k) - \sigma \alpha \|f'(x^k)\|^2$$

Note que quando $f'(x^k) \neq 0$, temos que $\frac{\langle f'(x^k), d^k \rangle}{\|d^k\|^2} \leq \delta < 0$ é satisfeita tomando $\delta = -1$, logo a estimativa de passo mais longo é dado por

$$\bar{\alpha}_k = \frac{2(1 - \sigma)}{L}$$

Como essa estimativa não depende de k quando o gradiente é Lipschitz-contínuo pelo lema (6.2) e suas consequências temos

$$\alpha_k \geq \check{\alpha} > 0$$

Onde $\check{\alpha}$ não depende de k

Teorema 7.1. (Convergência Global do Método do Gradiente I) *Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável em \mathbb{R}^n com derivada Lipschitz-contínua em \mathbb{R}^n com módulo $L > 0$. Então, se uma sequência $\{x^k\}$ gerada pelo método do gradiente (equipado com a Regra de Armijo) possui um ponto de acumulação, ou se f é limitada inferiormente em \mathbb{R}^n , tem-se*

que

$$\{f'(x^k)\} \rightarrow 0 \quad (k \rightarrow \infty)$$

Em particular, qualquer ponto de acumulação de $\{x^k\}$ é um ponto estacionário.

Demonstração. Se $f'(x^k) \neq 0, \forall k$, então $f(x^{k+1}) < f(x^k)$, o que implica que a sequência $\{f(x^k)\}$ é decrescente. Suponha que $\{x^{k_j}\} \rightarrow a$, onde $\{x^{k_j}\}$ é uma subsequência de $\{x^k\}$, e a é um ponto de acumulação da sequência. Pela continuidade de f , temos que $\{f(x^{k_j})\} \rightarrow f(a)$. No caso em que f é limitada inferiormente em \mathbb{R}^n , concluímos que $\{f(x^k)\}$ é monótona e decrescente, portanto converge. Sendo assim, $f(x^k) - f(x^{k+1}) \rightarrow 0, (k \rightarrow \infty)$.

Pela regra de Armijo, temos:

$$\begin{aligned} f(x^k - \alpha_k f'(x^k)) &\leq f(x^k) - \sigma \alpha_k \|f'(x^k)\|^2 \\ \Rightarrow f(x^{k+1}) - f(x^k) &\leq -\sigma \alpha_k \|f'(x^k)\|^2 \\ \Rightarrow f(x^k) - f(x^{k+1}) &\geq \sigma \alpha_k \|f'(x^k)\|^2 \end{aligned}$$

Como $f'(x^k)$ é Lipschitz-contínuo, temos que vale $\alpha_k \leq \tilde{\alpha} \leq 0$. Sendo assim,

$$f(x^k) - f(x^{k+1}) \geq \sigma \alpha_k \|f'(x^k)\|^2 \geq \sigma \tilde{\alpha} \|f'(x^k)\|^2 \geq 0$$

Tomando limite quando $k \rightarrow \infty$, temos pelo teorema do confronto que $f'(x^k) = 0$. Como f é contínua, segue que $\lim_{k \rightarrow \infty} f(x^k) = f(a)$. Como f é contínua, $\{f'(x^k)\} \rightarrow 0$.

Obs.: Esse mesmo argumento é válido para a subsequência $\{x^{k_j}\}$. □

No caso da minimização unidimensional e Armijo, podemos substituir a hipótese de $f'(x^k)$ ser Lipschitz-contínuo, por $f'(x^k)$ ser apenas contínua, que é uma condição mais frac. Note que $f'(x)$ não ser Lipschitz-contínuo, implica que nem sempre existe $\tilde{\alpha} > 0$, tal que $\alpha_k \geq \tilde{\alpha} > 0$, onde $\tilde{\alpha}$ não depende de k , ou seja, possa ser que $\alpha_k \rightarrow 0$

Teorema 7.2. (Convergência global do Método do gradiente II) Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável no \mathbb{R}^n com derivada contínua, seja também a sequência $\{x^k\}$, gerada pelo método do gradiente (equipado com a Regra de Armijo). Então cada ponto de acumulação da sequência é um ponto estacionário do problema. Se $\{x^k\}$ é limitada vale

$$\{f'(x^k)\} \rightarrow 0 (k \rightarrow \infty)$$

Demonstração. Suponha que $\{x^k\}$ tenha um ponto de acumulação $\bar{x} \in \mathbb{R}^n$. Suponhamos que a subsequência $\{x^{k_j}\} \rightarrow \bar{x}$, caso exista $\tilde{\alpha} > 0$ tal que $\alpha_{k_j} \geq \tilde{\alpha} > 0, \forall j$, onde $\tilde{\alpha}$, de maneira

análoga ao teorema anterior concluímos que $f'(\bar{x}) = 0$, quando $(j \rightarrow \infty)$.

Caso não $\tilde{\alpha}$ com tal propriedade, podemos supor que $\alpha_{k_j} \rightarrow 0$. Pela maneira que a Regra de armijo é construída (Tomando $\hat{\alpha}, \theta\hat{\alpha}, \theta^2\hat{\alpha}, \dots$), para algum j suficientemente grande, temos que α_{k_j} satisfaz Armijo, isso implica que $\theta^{-1}\hat{\alpha}$ não satisfaz Armijo, ou seja

$$f(x^{k_j} - \theta^{-1}\alpha_{k_j}f'(x^{k_j})) > f(x^{k_j}) - \sigma\theta^{-1}\alpha_{k_j}\|f'(x^{k_j})\|^2$$

Denotando por $\tilde{\alpha}_{k_j} = \theta^{-1}\alpha_{k_j}\|f'(x^{k_j})\|$, temos

$$\frac{f(x^{k_j} - \tilde{\alpha}_{k_j}\frac{f'(x^{k_j})}{\|f'(x^{k_j})\|}) - f(x^{k_j})}{\tilde{\alpha}_{k_j}} > -\sigma\|f'(x^{k_j})\| \quad (10)$$

Como $\varphi_{k_j}(\alpha) = f(x^{k_j} + \alpha d^{k_j})$, onde $d^{k_j} = -\frac{f'(x^{k_j})}{\|f'(x^{k_j})\|}$, de (10), temos

$$\frac{\varphi_{k_j}(\tilde{\alpha}_{k_j}) - \varphi_{k_j}(0)}{\tilde{\alpha}_{k_j}} \geq -\sigma\|f'(x^{k_j})\|$$

Note que pelo teorema do valor intermediário segue que

$$\frac{\varphi_{k_j}(\tilde{\alpha}_{k_j}) - \varphi_{k_j}(0)}{\tilde{\alpha}_{k_j}} = \varphi'_{k_j}(\alpha_{k_j}^*) = -\langle f'(x^{k_j} - \alpha_{k_j}^* d^{k_j}), d^{k_j} \rangle$$

Onde $0 \leq \alpha_{k_j}^* \leq \tilde{\alpha}_{k_j}$

Segue que

$$-\langle f'(x^{k_j} - \alpha_{k_j}^* d^{k_j}), d^{k_j} \rangle \geq -\sigma\|f'(x^{k_j})\|$$

Ou ainda

$$\langle f'(x^{k_j} - \alpha_{k_j}^* d^{k_j}), d^{k_j} \rangle \leq \sigma\|f'(x^{k_j})\|$$

Como $d^{k_j} = -\frac{f'(x^{k_j})}{\|f'(x^{k_j})\|}$, $\alpha_{k_j} \rightarrow 0$, quando $(j \rightarrow \infty)$ e $\{x^{k_j}\} \rightarrow \bar{x}$, temos que ao passar o limite quando $(j \rightarrow \infty)$

$$\|f'(\bar{x})\| < \sigma\|f'(\bar{x})\| \Rightarrow 0 \geq \|f'(\bar{x})\|(1 - \sigma)$$

E como $\sigma \in (0, 1)$, segue $f'(\bar{x}) = 0$

Como cada ponto de acumulação de qualquer sequência $\{x^k\}$ é um ponto estacionário do

problema de minimizar $f(x)$, $x \in \mathbb{R}^n$, concluímos que

$$f'(x^k) \rightarrow 0 \quad (k \rightarrow \infty).$$

□

Obs.: A existência de pontos de acumulação não faz parte da afirmação do teorema. uma hipótese que garante tal existência é supor que o conjunto $L(f(x)) = \mathcal{L}_{f, \mathbb{R}^n} f(x^0)$ seja limitado. Como $d \in \mathcal{D}f(x^0)$, temos que $f(x^k) < f(x^0)$ que implica $\{x^k\} \subset L(f(x^0))$, portanto $\{x^k\}$ será limitado e terá algum ponto de acumulação

Referências

- [1] A. Izmailov and M. Solodov. *Otimização, Volume 2: métodos computacionais*. IMPA, 2018.
- [2] A. Izmailov and M. Solodov. *Otimização, Volume 1*. Rio de Janeiro: IMPA, 2020.