

Algoritmo de ponto proximal para otimização em \mathbb{R}^n

Ilton Ferreira de Menezes ¹, Glaydston de Carvalho Bento ²

Instituto de Matemática e Estatística, Universidade Federal de Goiás, Campus II- Caixa Postal 131, CEP 74001-970 - Goiânia, GO, Brasil.

E-mail: iltomenezesufg@hotmail.com¹; glaydston@mat.ufg.br²

Palavras chaves: ponto proximal, funções convexas, subdiferencial.

1 Introdução

Considere o seguinte problema de otimização

$$\begin{aligned} \min f(x) \\ \text{t.q. } x \in \mathbb{R}^n, \end{aligned} \tag{1}$$

onde $f : \mathbb{R}^n \rightarrow \mathbb{R}$ (função objetivo) é não necessariamente diferenciável. O método de ponto proximal, introduzido por Martinet [1] e Rockafellar [2] na década de 70, é um método iterativo utilizado para resolver o problema (1). O método de ponto proximal gera uma sequência $\{x^k\} \subset \mathbb{R}^n$ como segue: dado $x_0 \in \mathbb{R}^n$,

$$x^{k+1} := \operatorname{argmin}_{x \in \mathbb{R}^n} \{f(x) + \lambda_k \|x - x^k\|^2\}, \tag{2}$$

onde $\{\lambda_k\}$ é uma sequência de números positivos. Sendo $f_k := f(x) + \lambda_k \|x - x^k\|^2$ uma regularização de f , espera-se que f_k forneça algum tipo de aproximação do minimizador (caso exista) da função objetivo f .

Neste trabalho, seguindo [3], mostramos que se f é convexa e o conjunto dos minimizadores é não vazio, então a sequência gerada por (2) está bem definida e converge um minimizador da função objetivo.

2 Objetivos

- Objetivos gerais: Estudo de elementos de análise convexa e análise não diferenciável;
- Objetivos específicos: Estudo do método de ponto proximal clássico para otimização convexa.

¹Orientando PIBIC CNPq

²Orientador

3 Metodologia

Estudo de livros e artigos e discussões semanais com o orientador.

4 Resultados e Discussões

4.1 Resultados preliminares

Nesta seção apresentamos algumas definições e resultados básicos de análise convexa que podem ser encontrados, por exemplo, em [4, 5, 6]. Daqui em diante, f sempre designará uma função definida em \mathbb{R}^n e assumindo valores em \mathbb{R} , salvo menção explícita em contrário.

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

Definição 2. Seja $D \subset \mathbb{R}^n$ um conjunto convexo. Uma função $f : D \rightarrow \mathbb{R}$ é dita ser convexa em D quando, para quaisquer $x, y \in D$ e $\alpha \in [0, 1]$, tem-se

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

Se a desigualdade estrita ocorre para $x \neq y$ e $\alpha \in (0, 1)$, então f é dita ser estritamente convexa.

Proposição 1. Seja f é uma função convexa e $h : \mathbb{R}^n \rightarrow \mathbb{R}$ é uma função estritamente convexa. Então, $f + h : \mathbb{R}^n \rightarrow \mathbb{R}$ é uma função estritamente convexa.

Demonstração. Segue imediatamente da última definição. □

Proposição 2. Seja f uma função estritamente convexa. Se f possui um minimizador, ele é único.

Demonstração. Suponhamos que f admita dois minimizadores $x, x' \in \mathbb{R}^n$, $x \neq x'$, com $f(x) = f(x') = \bar{v}$. Visto que f é estritamente convexa, para $\alpha \in (0, 1)$, temos que

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

que é um absurdo. Logo, o resultado segue. □

Teorema 3. (*Desigualdade de Jensen*) Seja f uma função convexa. Então, para todo $m \in \mathbb{N}$, $x_i \in \mathbb{R}^n$ e $\lambda_i \geq 0$, $i = 1, \dots, m$, tais que $\sum_{i=1}^m \lambda_i = 1$, tem-se

$$f\left(\sum_{i=1}^m \lambda_i x_i\right) \leq \sum_{i=1}^m \lambda_i f(x_i).$$

Demonstração. A prova é feita por indução a partir da Definição 2. □

Definição 3. Seja $x \in \mathbb{R}^n$ e $L > 0$. Uma função f é dita ser localmente Lipschitz em x com constante L , se existe uma $\epsilon > 0$ tal que

$$|f(x) - f(y)| \leq L\|x - y\|, \quad x, y \in \mathbb{R}^n.$$

Teorema 4. Seja f uma função convexa. Então, f é localmente Lipschitz.

Demonstração. Tome $u \in \mathbb{R}^n$ arbitrário (fixado). Afirmamos que f é limitada em uma vizinhança de u . De fato, seja $\epsilon > 0$ e considere a caixa

$$S := \{y \in \mathbb{R}^n : -\epsilon \leq y_i - u_i \leq \epsilon, \quad i = 1, \dots, n\},$$

com vértices u^1, \dots, u^m . É conhecido que $m = 2^n$ e $S = \text{conv}(\{u^1, \dots, u^m\})$ (envoltória convexa de $\{u^1, \dots, u^m\}$), ver [5, página 121]. Então, para cada $y \in S$, existem $\lambda_i \geq 0$, $i = 1, \dots, m$, com $\sum_{i=1}^m \lambda_i = 1$, tal que $y = \sum_{i=1}^m \lambda_i u_i$. Denote por M o máximo de f em $\{u^1, \dots, u^m\}$. Visto que f é convexa e $\sum_{i=1}^m \lambda_i = 1$, do Teorema 4 segue que

$$f(y) = f\left(\sum_{i=1}^m \lambda_i u_i\right) \leq \sum_{i=1}^m \lambda_i f(u_i) \leq M \sum_{i=1}^m \lambda_i = M,$$

o que prova que f é limitada superiormente por M quando restrita ao conjunto S . Por outro lado, para qualquer $y \in S$, existe $x \in S$ tal que $u = \frac{1}{2}x + \frac{1}{2}y$. Assim, pela convexidade de f , temos que $f(u) \leq \frac{1}{2}f(x) + \frac{1}{2}f(y)$, de onde obtemos que

$$f(y) \geq 2f(u) - f(x).$$

Agora, visto que $x \in S$ e f é limitada superiormente por M quando restrita ao conjunto S , da última desigualdade podemos concluir que f é limitada inferiormente por $2f(u) - M$ quando restrita ao conjunto S e a afirmação está provada.

Consideremos a bola $B(u, 2\delta)$ onde f é limitada e sejam α e β tais que

$$\alpha \leq f(z) \leq \beta, \quad z \in B(u, 2\delta). \tag{3}$$

Dados $y, y' \in B(u, \delta)$, $y \neq y'$ é fácil ver que

$$y'' = y' + \delta \frac{y' - y}{\|y' - y\|} \in B(u, 2\delta).$$

Além disso, $y' = \frac{\|y' - y\|}{\delta + \|y' - y\|} y'' + \frac{\delta}{\delta + \|y' - y\|} y$. Assim, visto que f é convexa, obtemos

$$f(y') \leq \frac{\|y' - y\|}{\delta + \|y' - y\|} f(y'') + \frac{\delta}{\delta + \|y' - y\|} f(y).$$

Sutraindo $f(y)$ de ambos os lados da última desigualdade, segue que

$$f(y') - f(y) \leq \frac{\|y' - y\|}{\delta + \|y' - y\|} [f(y'') - f(y)]. \quad (4)$$

Agora, visto que $y, y' \in B(u, 2\delta)$, de (3), temos que $f(y'') \leq \beta$ e $-f(y) \leq -\alpha$ e, consequentemente,

$$\frac{\|y' - y\|}{\delta + \|y' - y\|} [f(y'') - f(y)] \leq \frac{\|y' - y\|}{\delta} (\beta - \alpha).$$

Assim, combinando última desigualdade com (4), concluímos que

$$f(y') - f(y) \leq \frac{\|y' - y\|}{\delta} (\beta - \alpha).$$

Procedendo de modo análogo, é possível mostrar que

$$f(y) - f(y') \leq \frac{\|y' - y\|}{\delta} (\beta - \alpha).$$

Portanto,

$$|f(y') - f(y)| \leq \frac{\beta - \alpha}{\delta} \|y' - y\|,$$

e o resultado segue. □

Corolário 5. *Seja f uma função convexa. Então, f é contínua.*

Demonstração. Segue do Teorema 4. □

Definição 4. *Sejam x e v um ponto e uma direção em \mathbb{R}^n , respectivamente. A derivada direcional de uma função f em x na direção v é definida por*

$$f'(x, d) := \lim_{t \downarrow 0} \frac{f(x + td) - f(x)}{t}.$$

Proposição 6. *Seja $x \in \mathbb{R}^n$ e f uma função convexa. Então, a derivada direcional em cada direção $v \in \mathbb{R}^n$ existe e satisfaz*

$$f'(x, d) := \inf_{t > 0} \frac{f(x + td) - f(x)}{t}.$$

Demonstração. Tome $v \in \mathbb{R}^n$ e definamos $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ dada por

$$\varphi(t) = \frac{f(x + tv) - f(x)}{t}.$$

Seja $\epsilon > 0$ e tome constantes t_1, t_2 tais que $0 < t_1 < t_2 < \epsilon$. Note que

$$\varphi(t_2) - \varphi(t_1) = \frac{(t_2 - t_1)f(x) + t_1f(x + t_2v) - t_2f(x + t_1v)}{t_1t_2}.$$

que, depois de algumas manipulações algébricas, fornece

$$\varphi(t_2) - \varphi(t_1) = \frac{1}{t_1} [(1 - t_1/t_2)f(x) + t_1/t_2f(x + t_2v) - f(x + t_1v)].$$

Agora, visto que $0 < t_1/t_2 < 1$ e f é convexa, da última igualdade, obtemos

$$\varphi(t_2) - \varphi(t_1) \geq \frac{1}{t_1} [f((1 - t_1/t_2)x + t_1/t_2(x + t_2v)) - f(x + t_1v)] \geq 0,$$

de onde concluímos que φ decresce quando t tende a zero por valores positivos.

Considere agora $0 < t < \epsilon$. Temos que

$$\varphi(t) - \varphi(-\epsilon/2) = \frac{\frac{1}{2}f(x + tv) + \frac{1}{2}f(x) + \frac{t}{\epsilon}f(x - \frac{\epsilon}{2}v) + (1 - \frac{t}{\epsilon})f(x) - 2f(x)}{t/2}.$$

Usando que f é convexa, última igualdade nos fornece

$$\varphi(t) - \varphi(-\epsilon/2) \geq \frac{f(x + t/2v) + f(x - t/2v) - 2f(x)}{t/2},$$

de onde obtemos

$$\varphi(t) - \varphi(-\epsilon/2) \geq \frac{1/2f(x + t/2v) + 1/2f(x - t/2v) - f(x)}{t/4}.$$

Usando novamente a convexidade de f no segundo membro da última desigualdade, temos

$$\varphi(t) - \varphi(-\epsilon/2) \geq \frac{f(x) - f(x)}{t/4} = 0,$$

o que implica que f é limitada inferiormente para $0 < t < \epsilon$ e o resultado da proposição segue. \square

Definição 5. *Seja S um conjunto não vazio em \mathbb{R}^n . A função $\sigma_S : \mathbb{R}^n \rightarrow \mathbb{R}$, definida por*

$$\sigma_S(x) := \sup \{ \langle s, x \rangle : s \in S \},$$

é chamada função suporte de S .

Proposição 7. *Sejam $A, B \subset \mathbb{R}^n$ conjuntos não vazios, convexos e compactos. Então,*

$$A \subset B \quad \text{se, e somente se,} \quad \sigma_A \leq \sigma_B.$$

Definição 6. *Dado $x \in \mathbb{R}^n$, o subdiferencial de uma função f em x , denotado por $\partial f(x)$, é o conjunto dos vetores $s \in \mathbb{R}^n$ satisfazendo*

$$f(y) \geq f(x) + \langle s, y - x \rangle, \quad y \in \mathbb{R}^n.$$

Teorema 8. *Seja f uma função convexa e $x \in \mathbb{R}^n$. Então,*

$$(i) \quad f'(x, v) = \sigma_{\partial f(x)}(v), \quad \text{para todo } v \in \mathbb{R}^n;$$

(ii) $\partial f(x)$ é um conjunto não vazio, convexo e compacto tal que $\partial f(x) \subset B(0; L)$, onde L é uma constante de Lipschitz de f em x .

Demonstração. Ver, por exemplo, [6, pág. 14 e 15]. □

Teorema 9. *Sejam $f, g : \mathbb{R}^n \rightarrow \mathbb{R}$ funções convexas. Então, para cada $x \in \mathbb{R}^n$,*

$$\sigma_{\partial f(x) + \partial g(x)}(v) = \sigma_{\partial f(x)}(v) + \sigma_{\partial g(x)}(v), \quad v \in \mathbb{R}^n.$$

Demonstração. Tome $v \in \mathbb{R}^n$. Visto que f e g são convexas, pelo item (ii) do Teorema 8 podemos concluir que existem $\tilde{s}_1 \in \partial f(x)$ e $\tilde{s}_2 \in \partial g(x)$ tal que

$$\sigma_{\partial f(x)}(v) = \langle \tilde{s}_1, v \rangle, \quad \sigma_{\partial g(x)}(v) = \langle \tilde{s}_2, v \rangle. \quad (5)$$

Além disso, da Definição 5 segue que

$$\sigma_{\partial f(x) + \partial g(x)}(v) \geq \langle s_1 + s_2, v \rangle, \quad s_1 \in \partial f(x), \quad s_2 \in \partial g(x).$$

Assim, de (5), obtemos que

$$\sigma_{\partial f(x) + \partial g(x)}(v) \geq \sigma_{\partial f(x)}(v) + \sigma_{\partial g(x)}(v). \quad (6)$$

Por outro lado,

$$\sigma_{\partial f(x)}(v) + \sigma_{\partial g(x)}(v) \geq \langle s_1 + s_2, v \rangle, \quad s_1 \in \partial f(x), \quad s_2 \in \partial g(x),$$

o que implica que

$$\sigma_{\partial f(x)}(v) + \sigma_{\partial g(x)}(v) \geq \sigma_{\partial f(x) + \partial g(x)}(v).$$

Portanto, o resultado segue da última desigualdade combinada com a desigualdade (6). □

Teorema 10. *Sejam $f, g : \mathbb{R}^n \rightarrow \mathbb{R}$ funções convexas e $x \in \mathbb{R}^n$. Então,*

$$\partial(f + g)(x) = \partial f(x) + \partial g(x).$$

Demonstração. Tome $v \in \mathbb{R}^n$. Visto que f e g são convexas, pelo Teorema 8, segue que $\partial f(x)$ e $\partial g(x)$ são conjuntos não vazios, convexos e compactos tais que

$$\sigma_{\partial f(x)}v = f'(x, v), \quad \sigma_{\partial g(x)}v = g'(x, v). \quad (7)$$

Em particular, $\partial f(x) + \partial g(x)$ é um conjunto não vazio, convexo e compacto e, pelo Teorema 9,

$$\sigma_{\partial f(x) + \partial g(x)}v = \sigma_{\partial f(x)}v + \sigma_{\partial g(x)}v. \quad (8)$$

Por outro lado, visto que $(f + g)'(x, v) = f'(x, v) + g'(x, v)$, usando o item (i) do Teorema 8 junto com (7), obtemos

$$\sigma_{\partial(f+g)(x)}v = \sigma_{\partial f(x)}v + \sigma_{\partial g(x)}v.$$

Combinando última igualdade com (8) junto com a arbitrariedade de v , o resultado segue da Proposição 7. \square

Definição 7. *Seja f uma função contínua. Diz-se que f é uma 1-coerciva se*

$$\lim_{\|x\| \rightarrow +\infty} \frac{f(x)}{\|x\|} = +\infty.$$

Teorema 11. *Seja f uma função contínua. Se f é 1-coerciva, então f possui pelo menos um mínimo global.*

Demonstração. Visto que f é 1-coerciva, temos que $\lim_{\|x\| \rightarrow +\infty} \frac{f(x)}{\|x\|} = +\infty$. Consequentemente, dado $M \geq 0$ existe um número $r > 0$ tal que, para $\|x\| \geq r$ tem-se

$$\frac{f(x)}{\|x\|} \geq M \Leftrightarrow f(x) \geq M\|x\| \geq Mr.$$

Mas isto nos diz que

$$L_f(Mr) := \{x \in \mathbb{R}^n : f(x) \leq Mr\} \subset B(0, r) := \{x \in \mathbb{R}^n : \|x\| \leq r\}.$$

Visto que f é convexa, do Corolário (5), temos que f é contínua e conseqüentemente, $L_f(Mr)$ é fechado. Portanto, da última inclusão, $L_f(Mr)$ é um conjunto compacto. Assim, pelo Teorema de Weierstrass, f possui pelo menos um mínimo quando restrita a $L_f(Mr)$. Seja $y \in \mathbb{R}^n$ um minimizador de f restrita a $L_f(Mr)$. Afirmamos que y é um minimizador

irrestrito de f . De fato, visto que y é um minimizador de f quando restrita ao conjunto $L_f(Mr)$, temos que $f(y) \leq f(x)$, para todo $x \in L_f(Mr)$. Por outro lado, para todo $x \notin L_f(Mr)$,

$$f(x) > Mr \geq f(y),$$

e o resultado segue. \square

Proposição 12. *Seja f uma função convexa e $x \in \mathbb{R}^n$. Uma condição necessária e suficiente para que x seja um minimizador de f é que $0 \in \partial f(x)$.*

Demonstração. Segue imediatamente da definição de subdiferencial. \square

4.2 O método de ponto proximal

Nesta seção apresentamos uma análise de convergência do método de ponto proximal, ver por exemplo, [7, 3].

Proposição 13. *Seja f uma função convexa. A sequência $\{x^k\}$ gerada pelo método de ponto proximal (2) está bem definida.*

Demonstração. Pelo item (ii) do Teorema 8, para todo $k \in \mathbb{N}$, existe $s^k \in \mathbb{R}^n$ tal que

$$f(x) \geq f(x^k) + \langle s^k, x - x^k \rangle.$$

Assim, visto que $f_k(x) = f(x) + \lambda_k \|x^k - x\|^2$, temos que

$$f_k(x) \geq f(x^k) + \langle s^k, x - x^k \rangle + \lambda_k \|x^k - x\|^2.$$

Dividindo ambos os membros da desigualdade acima por $\|x - x^k\|$, obtemos

$$\frac{f_k(x)}{\|x - x^k\|} \geq \frac{f(x^k)}{\|x - x^k\|} + \left\langle s^k, \frac{x - x^k}{\|x - x^k\|} \right\rangle + \lambda_k \|x^k - x\|,$$

e, pela desigualdade de Cauchy-Schwarz, última desigualdade se reduz a

$$\frac{f_k(x)}{\|x - x^k\|} \geq \frac{f(x^k)}{\|x - x^k\|} - \|s^k\| + \lambda_k \|x^k - x\|.$$

Visto que $f(x^k)$ e $\|s^k\|$ são constantes e $\lambda_k > 0$, fazendo $\|x - x^k\|$ ir a $+\infty$ em ambos os membros da última desigualdade, segue que f_k é 1-coerciva. Assim, como $\lambda_k \|x^k - x\|^2$ é estritamente convexa, o resultado segue do Teorema 11 combinado com as Proposições 1 e 2. \square

Teorema 14. *Seja $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. A sequência $\{x^k\} \subset \mathbb{R}^n$ gerada por (2) é caracterizada pela relação*

$$2\lambda(x^k - x^{k+1}) \in \partial f(x^{k+1}).$$

Demonstração. Sendo x^{k+1} dada por (2), o resultado segue da Proposição 12 combinada com o Teorema 10. \square

Teorema 15. *Seja f uma função convexa e $x \in \mathbb{R}^n$. Se a sequência $\{x^k\}$ é gerada por (2), então vale a desigualdade*

$$\|x - x^{k+1}\|^2 \leq \|x - x^k\|^2 - \|x^{k+1} - x^k\|^2 + \frac{1}{\lambda_k}(f(x) - f(x^{k+1})).$$

Demonstração. Note que

$$\|x - x^{k+1}\|^2 = \|x - x^k + x^k - x^{k+1}\|^2 = \|x - x^k\|^2 - \|x^{k+1} - x^k\|^2 + 2\langle x^k - x^{k+1}, x - x^{k+1} \rangle \quad (9)$$

Agora, visto que f é convexa, pelo Teorema 14, temos

$$2\lambda_k(x^k - x^{k+1}) \in \partial f(x^{k+1}).$$

Assim, pela definição de $\partial f(x^{k+1})$,

$$f(x) \geq f(x^{k+1}) + \langle 2\lambda_k(x^k - x^{k+1}), x - x^{k+1} \rangle = f(x^{k+1}) + 2\lambda_k \langle x^k - x^{k+1}, x - x^{k+1} \rangle,$$

e, conseqüentemente,

$$\frac{1}{\lambda_k}(f(x) - f(x^{k+1})) \geq 2\langle x^k - x^{k+1}, x - x^{k+1} \rangle.$$

Portanto, o resultado segue da última desigualdade combinada com a desigualdade (9). \square

Corolário 16. *Seja $\{x^k\}$ a sequência gerada por (2). Então, vale a desigualdade*

$$\|x - x^{k+1}\|^2 \leq \|x - x^k\|^2 + \frac{1}{\lambda_k}(f(x) - f(x^{k+1})), \quad (10)$$

para todo $x \in \mathbb{R}^n$.

Demonstração. Segue do Teorema 15. \square

Definição 8. *Seja $\emptyset \neq U \subset \mathbb{R}^n$. Uma sequência $\{x^k\} \subset \mathbb{R}^n$ é dita ser Fejér convergente a U com respeito a norma euclidiana se*

$$\|x^{k+1} - u\| \leq \|x^k - u\|, \quad u \in U. \quad (11)$$

Corolário 17. Se $\{x^k\}$ é Fejér convergente ao conjunto $\emptyset \neq U^* \subset \mathbb{R}^n$, então $\{x^k\}$ é uma sequência limitada. Se, além disso, um ponto de acumulação \bar{x} da sequência $\{x^k\}$ pertence a U , então $\bar{x} = \lim_{k \rightarrow +\infty} x^k$.

Demonstração. Dado $u \in U$, a desigualdade (11) implica que $\|u - x^k\|^2 \leq \|u - x_0\|^2$, para todo k . Deste modo a sequência $\{x^k\}$ é limitada. Agora sejam $\bar{x} \in U$ um ponto de acumulação de $\{x^k\}$ e $\{x_{k_j}\}$ uma subsequência de $\{x^k\}$ tal que $\lim_{j \rightarrow +\infty} (x_{k_j}) = \bar{x}$. Como $\bar{x} \in U$, segue de (11) que a sequência de números reais positivos $\{\|x^k - \bar{x}\|\}$ é monótona não-decrescente e possui uma subsequência, a saber $\{\|x_{k_j} - \bar{x}\|\}$, convergindo para zero. Então a sequência converge para zero, isto é, $\lim_{k \rightarrow +\infty} \|x^k - \bar{x}\| = 0$, o que significa $\lim_{k \rightarrow +\infty} x^k = \bar{x}$. \square

Teorema 18. Sejam f uma função convexa e $\{x^k\}$ a sequência gerada por (2). Se a sequência $\{\lambda_k\}$ é tal que $\sum_{k=0}^{\infty} \frac{1}{\lambda_k} = +\infty$, então $\lim_{k \rightarrow +\infty} f(x^k) = f_*$, onde $f_* = \inf_{x \in \mathbb{R}^n} f(x)$. Se, além disso, o conjunto U^* dos minimizadores de f é não vazio, então $\lim_{x \rightarrow \infty} (x^k) = x_*$, com $x_* \in U^*$.

Demonstração. Seja U^* o conjunto dos minimizadores da função convexa f . Se $x^k \in U^*$, para algum $k > 0$, é fácil ver que $x^k = x^{k+1} = x^{k+2} = x^{k+3} = \dots$. Assim, $f(x^k) = f_*$ e não há mais nada a fazer. Agora, suponha que para todo $k \in \mathbb{N}$, $x^k \notin U^*$. Por (2), segue que a sequência $\{f(x^k)\}$ é estritamente decrescente. Afirmamos que $\lim_{k \rightarrow +\infty} f(x^k) = f_*$. De fato, suponhamos, por absurdo, que $\lim_{k \rightarrow +\infty} f(x^k) > f_*$. Então, existe $x \in \mathbb{R}^n$ e $\delta > 0$ tal que

$$f(x) < f(x^k) - \delta, \quad k \in \mathbb{N}. \quad (12)$$

Substituindo a desigualdade (12) na desigualdade (10), obtemos

$$\|x - x^{k+1}\|^2 \leq \|x - x^k\|^2 - \frac{\delta}{\lambda_k}, \quad k \in \mathbb{N}. \quad (13)$$

e, conseqüentemente,

$$\frac{\delta}{\lambda_k} \leq \|x - x^k\|^2 - \|x - x^{k+1}\|^2,$$

para todo $k > 0$. Somando termo a termo

$$\sum_{k=0}^j \frac{1}{\lambda_k} \leq \frac{1}{\delta} (\|x - x_0\|^2 - \|x - x^{j+1}\|^2) \leq \frac{1}{\delta} \|x - x_0\|^2,$$

para todo j , o que contraria $\sum_{k=0}^{\infty} \frac{1}{\lambda_k} = +\infty$. Logo, $\lim_{k \rightarrow +\infty} f(x^k) = f_*$. Suponhamos agora que $U^* \neq \emptyset$ e tome $\bar{x} \in U^*$. Deste modo $f(\bar{x}) \leq f(x^k)$, para todo k . Substituindo x por \bar{x}

em (10), obtemos

$$\|\bar{x} - x^{k+1}\|^2 \leq \|\bar{x} - x^k\|^2, \quad k \in \mathbb{N},$$

assegurando que a sequência $\{x^k\}$ é Fejér convergente a U^* . Logo, pelo corolário 17, temos que $\{x^k\}$ é limitada. Seja $\{x^{k_j}\}$ uma subsequência convergente de $\{x^k\}$, tal que $\lim_{j \rightarrow +\infty} x^{k_j} = x_*$. Da primeira parte $\lim_{j \rightarrow +\infty} f(x^{k_j}) = f_*$. Assim, visto que f é convexa, em particular f contínua (Corolário 5) e, conseqüentemente, $f(x_*) = f_*$. Mas isto nos diz que $x_* \in U^*$. Portanto, novamente pelo corolário 17, concluímos que a sequência $\{x^k\}$ converge a x_* , isto é, $\lim_{k \rightarrow \infty} (x^k) = x_*$. \square

5 conclusão

Neste trabalho estudamos o método de ponto proximal e apresentamos uma análise de convergência da sequência gerada pelo mesmo a uma solução do problema de minimização convexa irrestrito, no caso que a função objetivo é não necessariamente diferenciável.

Referências

- [1] Martinet B., Régularization, d'inéquations variationelles par approximations successives, Revue Française d'Informatique et de Recherche Opertionelle, (1970), 154-159.
- [2] Rockafellar, R. T., Monotone operators and the proximal point method, SIAM, J. Control. Optim., 14 (1970), 154-159.
- [3] Silva, S. R. P, Algoritmo de Ponto Proximal para Otimização em \mathbb{R}^n , UFG, Dissertação de mestrado, (2002).
- [4] Tiel, J. V., Convex analysis: an introductory text, Royal Neterland Meteorological Institute, 1984.
- [5] Izmailov, A., Solodov, M., Otimização Volume 1. Condições de otimalidade, elementos de análise conexa e de dualidade Rio de Janeiro: IMPA,2005.
- [6] Mäkelä, M. M., Nonsmooth optimization: analysis and algorithms with applications to optimal control Marko M., Mäkelä and Pekka Neitaanmäki.

- [7] Iusen, A.N., Proximal point methods in optimization, 20. Colóquio Brasileiro de Matemática, IMPA, (1995).