

UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA

ALGORITMO
DE PONTO PROXIMAL
PARA OTIMIZAÇÃO EM \mathbb{R}^n

por

Sandra Regina Peres da Silva

Dissertação de Mestrado em Matemática

Agradecimentos

Ao professor Doutor Orizon Pereira Ferreira pela escolha do tema, orientação e paciência, que muito contribuíram na elaboração desta dissertação.

À banca examinadora pelas sugestões que contribuíram para a melhoria deste trabalho.

Ao meu esposo Mauricio e ao meu filho Tiago pelo carinho, incentivo e compreensão durante a realização do curso de Mestrado.

Aos meus familiares, em especial à minha mãe Izabel, pelo incentivo irrestrito.

Aos colegas de curso, pela amizade e ajuda mútua.

Aos professores e funcionários do Instituto de Matemática e Estatística da UFG, pela oportunidade e apoio.

Ao meu esposo Mauricio e
ao meu filho Tiago

Resumo

Nesta dissertação estudamos um algoritmo conceitual para minimização de uma função convexa, não necessariamente diferenciável, conhecido por *algoritmo de ponto proximal*. Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. O algoritmo de ponto proximal é um processo iterativo que, a partir de um ponto inicial $x_0 \in \mathbb{R}^n$, gera recursivamente uma seqüência de pontos $\{x_k\} \subset \mathbb{R}^n$ pela iteração: $x_{k+1} := \arg \min_{x \in \mathbb{R}^n} \{f(x) + \lambda_k \|x_k - x\|^2\}$, onde $\{\lambda_k\}$ é uma seqüência de números positivos.

Mostramos, primeiramente, que a função estritamente convexa $f_k(x) := f(x) + \lambda_k \|x_k - x\|^2$ possui um único minimizador. Logo, o algoritmo está bem definido. Em seguida estabelecemos a convergência do algoritmo baseados na *Fejér* convergência da seqüência $\{x_k\}$ ao conjunto dos minimizadores da função convexa f , caso ele seja não vazio. Caso a função convexa f não possua minimizador mostramos que a seqüência gerada pelo algoritmo divergirá.

Também estudamos o algoritmo de ponto proximal para operadores monótonos maximais arbitrários, $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$. Mostramos que este algoritmo está bem definido e que, se existir $\bar{x} \in \mathbb{R}^n$ tal que $0 \in T(\bar{x})$, a seqüência gerada pelo algoritmo convergirá para uma singularidade do operador. Além disso, mostramos que o subdiferencial de uma função convexa é um operador monótono maximal e assim, determinar suas singularidades generaliza, em um certo sentido, o problema de minimização convexa.

Abstract

In this dissertation, we study a conceptual algorithm for minimization of the convex function, not necessarily differential, known by *proximal point algorithm*. Let $f: \mathbb{R}^n \rightarrow \mathbb{R}$ be a convex function. The proximal point algorithm is an iterative procedure, which starts at a point $x_0 \in \mathbb{R}^n$, generate recursively a sequence of points $\{x_k\} \subset \mathbb{R}^n$ by iteration: $x_{k+1} := \arg \min_{x \in \mathbb{R}^n} \{f(x) + \lambda_k \|x_k - x\|^2\}$, where $\{\lambda_k\}$ is a sequence of positive numbers.

We show, firstly, that the strictly convex function $f_k(x) := f(x) + \lambda_k \|x_k - x\|^2$ has a unique minimizer. Thus, the algorithm is well defined. Next we establish the convergence of algorithm based upon the of *Fejér* convergence of sequence $\{x_k\}$ to set of minimizers of the convex function f , case it is not empty. If the convex function f not has minimizer we show that the sequence generate for the algorithm diverge.

We also study the proximal point algorithm for arbitrary maximal monotone operators, $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$. We show that this algorithm is well defined and that, if exists $\bar{x} \in \mathbb{R}^n$ such that $0 \in T(\bar{x})$, the sequence generated for algorithm converge to a singularity of the operator. In addition, we show that the subdifferential of the a convex function is a maximal monotone operator and so, to determine its singularities generalizes, in a certain sense, the convex minimization problem.

Índice

I	Introdução	9
II	Topologia do \mathbb{R}^n	11
II.1	Introdução	11
II.2	Noções topológicas no espaço Euclidiano	11
II.3	Seqüências no espaço Euclidiano	13
II.4	Funções contínuas	14
III	Análise convexa	17
III.1	Introdução	17
III.2	Conjuntos convexos	18
III.3	Funções convexas	22
IV	Algoritmo de ponto proximal para otimização em \mathbb{R}^n	39
IV.1	Introdução	39
IV.2	Algoritmo de ponto proximal	40
IV.2.1	Boa definição	40
IV.2.2	Convergência	42
IV.3	Observações finais	45

V Operadores Monótonos Maximais	47
V.1 Introdução	47
V.2 Operadores Monótonos contínuos	48
V.3 Operadores monótonos ponto-conjunto	50
VI O algoritmo para operadores monótonos maximais	55
VI.1 Introdução	55
VI.2 O algoritmo	56
VI.2.1 Boa definição	57
VI.2.2 Convergência	58
VI.2.3 Observações finais	60

CAPÍTULO I

Introdução

Nesta dissertação estudaremos um algoritmo conceitual para minimização de uma função $f: \mathbb{R}^n \rightarrow \mathbb{R}$ convexa, não necessariamente diferenciável. Esse algoritmo, conhecido por *algoritmo de ponto proximal* de acordo com a terminologia de Rockafellar [10], foi aplicado pela primeira vez em otimização convexa por Martinet [6], na década de 70.

O algoritmo de ponto proximal é um processo iterativo para minimizar uma função convexa que, a partir de um ponto inicial $x_0 \in \mathbb{R}^n$, gera recursivamente uma seqüência de pontos $\{x_k\} \subset \mathbb{R}^n$ pela iteração:

$$x_{k+1} := \arg \min_{x \in \mathbb{R}^n} \{f(x) + \lambda_k \|x_k - x\|^2\},$$

onde $\{\lambda_k\}$ é uma seqüência de números positivos. A iteração acima foi introduzida por Moreau [8] no ano de 1965.

Para estabelecer a convergência do algoritmo de ponto proximal, uma suposição usual é a existência de um mínimo da função objetivo; isto é, se existe $x_* \in \mathbb{R}^n$ tal que $f(x_*) \leq f(x)$, para todo $x \in \mathbb{R}^n$, então a seqüência $\{x_k\}$ converge a este minimizador. Esta suposição foi retirada por Osman Güller [2] em 1991, ou seja, se a função objetivo não possui minimizador,

então a seqüência $\{x_k\}$ diverge. Em 1993, Rafael Correa e Claude Lemaréchal [1] estabeleceram de maneira simples e unificada a convergência de vários métodos de minimização convexa, dentre eles, o método de ponto proximal. A análise de convergência que faremos baseia-se na noção de Fejér convergência da seqüência $\{x_k\}$ ao conjunto dos minimizadores da função convexa f (veja Iusem [4]).

O algoritmo de ponto proximal também é fundamental para resolver o problema de encontrar singularidades de operadores monótonos maximais. Estudaremos este importante resultado devido à Rockafellar [11], pois o problema de encontrar pontos singulares de operador monótono maximal generaliza o problema de minimização de funções convexas.

Com o objetivo de tornar este trabalho mais completo, destinamos o Capítulo II à uma breve revisão de análise no \mathbb{R}^n e o Capítulo III à um resumo dos conceitos básicos, relativos aos conjuntos convexos e às funções convexas, que serão necessários ao desenvolvimento dos capítulos seguintes. Apesar dos conceitos de análise convexa já serem conhecidos, nós os discutiremos com detalhes, principalmente para uniformizar as notações.

A parte central deste trabalho encontra-se nos Capítulos IV e VI. No Capítulo IV mostraremos que o algoritmo de ponto proximal para minimização convexa está bem definido e que a seqüência gerada por ele converge para um minimizador da função, caso exista algum. No Capítulo V, introduziremos o conceito de operadores monótonos em \mathbb{R}^n , operadores monótonos ponto-conjunto e operadores monótonos maximais e encerraremos o capítulo mostrando que o subdiferencial de uma função convexa é um operador monótono maximal. Finalmente, no Capítulo VI estudaremos o algoritmo de ponto proximal para operadores monótonos maximais arbitrários, $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$. Mostraremos que este algoritmo está bem definido e que, se existir $\bar{x} \in \mathbb{R}^n$ tal que $0 \in T(\bar{x})$, a seqüência gerada pelo algoritmo convergirá para uma singularidade do operador.

CAPÍTULO II

Topologia do \mathbb{R}^n : Um resumo dos conceitos básicos

II.1 Introdução

Neste capítulo apenas enunciaremos alguns conceitos relacionados à topologia do espaço Euclidiano, os quais serão utilizados nos Capítulos III e IV. Por tratarem-se de resultados básicos de análise no \mathbb{R}^n as demonstrações serão omitidas e poderão ser encontradas na referência [5].

II.2 Noções topológicas no espaço Euclidiano

A *bola aberta* de centro $a \in \mathbb{R}^n$ e raio $r > 0$ é o conjunto dos pontos $x \in \mathbb{R}^n$ cuja distância ao ponto a é menor do que r . Usaremos a notação $B(a; r)$ para indicar esse conjunto. Assim

$$B(a; r) = \{x \in \mathbb{R}^n : \|x - a\| < r\}.$$

Definição II.2.1. Um conjunto $X \subset \mathbb{R}^n$ diz-se *limitado* quando existe um número real $c > 0$ tal que $\|x\| \leq c$ para todo $x \in X$.

Seja $X \subset \mathbb{R}^n$. Um ponto $a \in X$ chama-se um *ponto interior* a X quando é centro de alguma bola aberta contida em X , ou seja, quando existe $\delta > 0$ tal que $\|x - a\| < \delta$ implica $x \in X$. O *interior* de X é o conjunto $\text{int } X$, formado pelos pontos interiores a X . Quando $x \in \text{int } V$, dizemos que o conjunto V é uma *vizinhança* do ponto x .

Definição II.2.2. Um conjunto $X \subset \mathbb{R}^n$ chama-se *aberto* quando todos os seus pontos são interiores, isto é, quando para cada $x \in X$ existe $\delta > 0$ tal que $B(x; \delta) \subset X$.

Definição II.2.3. Seja $X \subset \mathbb{R}^n$. Um ponto $a \in \mathbb{R}^n$ chama-se *ponto de acumulação* do conjunto X quando toda bola aberta de centro a contém algum ponto de X , diferente do ponto a . Noutros termos, para todo $\epsilon > 0$, deve existir $x \in X$ tal que $0 < \|x - a\| < \epsilon$.

Diz-se que um ponto x é um *ponto de aderência* de um conjunto $X \subset \mathbb{R}^n$, se qualquer vizinhança de x contém algum elemento de X . Isso significa que x pode ser um elemento de X ou não, mas se não for certamente será ponto de acumulação de X . O conjunto dos pontos aderentes a X chama-se o *fecho* de X .

Definição II.2.4. Um conjunto $X \subset \mathbb{R}^n$ chama-se *fechado* quando contém todos os seus pontos de aderência.

O teorema a seguir caracteriza os conjuntos fechados.

Teorema II.2.5. *Um conjunto é fechado se, e somente se, seu complementar é aberto.*

Definição II.2.6. Diremos que um conjunto $K \subset \mathbb{R}^n$ é *compacto* quando ele for fechado e limitado.

II.3 Seqüências no espaço Euclidiano

Uma *seqüência* em \mathbb{R}^n é uma função $x: \mathbb{N} \rightarrow \mathbb{R}^n$ definida no conjunto \mathbb{N} dos números naturais. O valor que essa função assume no número k é indicado com x_k e chama-se o k -ésimo termo da seqüência. Usaremos a notação $\{x_k\}$ para indicar a seqüência cujo k -ésimo termo é $x_k \in \mathbb{R}^n$. Uma *subseqüência* de $\{x_k\}$ é a restrição da seqüência a um subconjunto infinito $\mathbb{N}' = \{k_1 < k_2 < \dots < k_i < \dots\} \subset \mathbb{N}$. Indicaremos uma subseqüência pela notação $\{x_{k_j}\}$.

Diz-se que a seqüência $\{x_k\}$ é *limitada* quando o conjunto dos seus termos é limitado em \mathbb{R}^n , ou seja, quando existe um número real $c > 0$ tal que $\|x_k\| \leq c$ para todo $k \in \mathbb{N}$.

Uma seqüência $\{x_k\}$ de números reais chama-se *monótona não-decrescente* quando se tem $x_k \leq x_{k+1}$ para todo $k \in \mathbb{N}$ e chama-se *monótona não-crescente* quando se tem $x_{k+1} \leq x_k$ para todo $k \in \mathbb{N}$.

Quando existe o limite $a = \lim_{k \rightarrow +\infty} x_k$, diz-se que a seqüência $\{x_k\}$ é convergente.

Os teoremas enunciados a seguir têm papéis importantes na demonstração da convergência do algoritmo de ponto proximal para funções convexas. Tratam-se de resultados clássicos de análise no \mathbb{R}^n , por isso as demonstrações serão omitidas.

Teorema II.3.1. *Dados $X \subset \mathbb{R}^n$ e $a \in \mathbb{R}^n$, as seguintes afirmações são equivalentes:*

- (i) *a é ponto de acumulação de X ;*
- (ii) *Existe uma seqüência de pontos $x_k \in X$, com $\lim_{k \rightarrow +\infty} x_k = a$ e $x_k \neq a$ para todo $k \in \mathbb{N}$;*
- (iii) *Toda bola aberta de centro a contém uma infinidade de pontos de X .*

Teorema II.3.2. *(Bolzano-Weierstrass) Toda seqüência limitada em \mathbb{R}^n possui uma subseqüência convergente.*

Teorema II.3.3. *Toda seqüência monótona limitada é convergente.*

Teorema II.3.4. *Toda subsequência de uma seqüência convergente converge para o mesmo limite da seqüência.*

II.4 Funções contínuas

A propriedade de continuidade das funções convexas permitirá, dentre outros resultados, mostrar a boa definição do algoritmo de ponto proximal. Enunciaremos nesta seção os principais teoremas que serão utilizados no Capítulo IV.

Seja $f: X \rightarrow \mathbb{R}$ uma função definida no conjunto $X \subset \mathbb{R}^n$. Diz-se que f é *contínua* no ponto $a \in X$ quando, para qualquer $\epsilon > 0$ dado, pode-se obter $\delta > 0$ tal que $\|x - a\| < \delta$ implica $|f(x) - f(a)| < \epsilon$. Se $f: X \rightarrow \mathbb{R}$ é contínua em todos os pontos do conjunto X , diz-se simplesmente que f é uma função *contínua*.

Dado $X \subset \mathbb{R}^n$, uma função $f: X \rightarrow \mathbb{R}$ diz-se *Lipschitziana* quando existe $L > 0$ (constante de Lipschitz de f) tal que, para quaisquer $x, y \in X$, tem-se

$$|f(x) - f(y)| \leq L\|x - y\|.$$

Toda função Lipschitziana é contínua: dado $\epsilon > 0$, basta tomar $\delta = \frac{\epsilon}{L}$. Então $\|x - a\| < \delta$ implica $|f(x) - f(a)| \leq L\|x - a\| < L \cdot \frac{\epsilon}{L} = \epsilon$.

Definição II.4.1. Diz-se que uma função $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é *localmente lipschitziana* quando, para todo $x_0 \in \mathbb{R}^n$, existem $L_{x_0} > 0$ e $\delta > 0$, tais que $|f(x) - f(y)| \leq L_{x_0}\|x - y\|$, para todo $x, y \in B(x_0; \delta)$.

Teorema II.4.2. *Seja $f: X \rightarrow \mathbb{R}^n$ uma função definida no subconjunto $X \subset \mathbb{R}^n$. f é contínua no ponto $a \in X$ se, e somente se, para toda seqüência de pontos $x_k \in X$ com $\lim_{k \rightarrow +\infty} x_k = a$, tem-se $\lim_{k \rightarrow +\infty} f(x_k) = f(a)$.*

Teorema II.4.3. (Weierstrass) *Seja $f: K \rightarrow \mathbb{R}$ uma função contínua, definida num conjunto compacto $K \subset \mathbb{R}^n$. Então f atinge seu máximo e seu mínimo em K ; isto é, existem pontos $x_0, x_1 \in K$ tais que $f(x_0) \leq f(x) \leq f(x_1)$ para qualquer $x \in K$.*

Teorema II.4.4. (Teorema do Valor Médio) *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ diferenciável. Dados $x, y \in \mathbb{R}^n$, existe um ponto ξ no segmento ligando x a y tal que*

$$f(y) - f(x) = \sum_{i=1}^n \frac{\partial f}{\partial x_i}(\xi) \cdot (y - x)_i, \quad (\text{II.4.1})$$

onde $(y - x)_i$ é a i -ésima componente do vetor $(y - x) \in \mathbb{R}^n$.

Podemos escrever a equação (II.4.1) na forma

$$f(y) - f(x) = \langle \nabla f(\xi), y - x \rangle.$$

CAPÍTULO III

Análise convexa: Um resumo dos conceitos básicos

III.1 Introdução

Destinamos este capítulo a um estudo dos conceitos relacionados aos conjuntos convexos e às funções convexas em \mathbb{R}^n , os quais utilizaremos no restante desta dissertação. Para uniformizar as notações e tornar este trabalho “autocontido”, demonstraremos a grande maioria dos resultados. As definições e os teoremas enunciados no capítulo anterior, juntamente com os resultados apresentados aqui, são o instrumental necessário para o desenvolvimento do algoritmo de ponto proximal que será introduzido no Capítulo IV. Os resultados de análise convexa em \mathbb{R}^n utilizados nesta seção encontram-se em [3], [10] e [12].

III.2 Conjuntos convexos

Definição III.2.1. Um conjunto $C \subset \mathbb{R}^n$ é dito *convexo* se $\alpha x + (1 - \alpha)x'$ pertence a C , sempre que x e x' pertencem a C , e $\alpha \in [0, 1]$.

Geometricamente, esta definição nos diz que o segmento de reta

$$[x, x'] := \{\alpha x + (1 - \alpha)x' : 0 \leq \alpha \leq 1\}$$

está inteiramente contido em C , sempre que os pontos extremos x e x' estão em C .

Definição III.2.2. Dada $f: \mathbb{R}^n \rightarrow \mathbb{R}$, o *epigráfico* de f é o conjunto não vazio

$$\text{epi } f := \{(x, r) \in \mathbb{R}^n \times \mathbb{R} : r \geq f(x)\}.$$

O epigráfico de uma função linear é caracterizado por um vetor $s \in \mathbb{R}^n$, e tem a forma $\{(x, r) \in \mathbb{R}^n \times \mathbb{R} : \langle s, x \rangle - r \leq 0\}$. Assim, o epigráfico de funções afins, são convenientemente escritos em termos de algum $x_0 \in \mathbb{R}^n$:

$$\{(x, r) : r \geq f(x_0) + \langle s, x - x_0 \rangle\} = \{(x, r) : \langle s, x \rangle - r \leq \langle s, x_0 \rangle - f(x_0)\}.$$

As funções afins possuem papel importante no contexto da análise convexa estudada aqui. Mostraremos no Teorema III.3.4 que se f é uma função convexa então f é minorizada por alguma função afim. A definição de hiperplano suporte e um breve estudo sobre projeção auxiliarão na demonstração do teorema citado acima.

Definição III.2.3. (Hiperplano Suporte) Dado um conjunto $C \subset \mathbb{R}^n$ com fronteira $\partial C \neq \emptyset$ e um ponto $x \in \partial C$, considere o hiperplano afim $H_{s,r} = \{y \in \mathbb{R}^n : \langle s, y \rangle = r\}$ para $s \in \mathbb{R}^n$ e $r \in \mathbb{R}$. Dizemos que $H_{s,r}$ é *suporte* ao conjunto C em x se vale a desigualdade:

$$\langle s, x \rangle \leq r,$$

para todo $x \in C$ e, além disso, $x \in H_{s,r}$.

Seja $C \neq \emptyset$ um conjunto convexo fechado em \mathbb{R}^n . Para $x \in \mathbb{R}^n$ fixado, consideremos o seguinte problema:

$$\inf\{\|y - x\|^2 : y \in C\}. \quad (\text{III.2.1})$$

Dado $c \in C$, tome um conjunto de sub-nível $S := \{y \in \mathbb{R}^n : \|y - x\| \leq \|c - x\|\}$. Então (III.2.1) é equivalente a

$$\inf\{\|y - x\| : y \in C \cap S\},$$

o qual possui uma solução, pois $y \mapsto \|y - x\|$ é contínua, S é compacto e $C \cap S$ é compacto. Portanto, deduzimos a *existência* de um ponto em C que minimiza a distância a x e desta forma (III.2.1) é de fato um mínimo. Veremos que existe um único ponto que minimiza a distância de x ao convexo C .

Teorema III.2.4. *Seja $x \in \mathbb{R}^n$. Se, para algum $y_x \in C$ tem-se $\|y_x - x\| \leq \|y - x\|$, para todo $y \in C$, então*

$$\langle x - y_x, y - y_x \rangle \leq 0, \quad (\text{III.2.2})$$

para todo $y \in C$.

Demonstração. Tome y arbitrário em C , de modo que $y_x + \alpha(y - y_x) \in C$, para todo $\alpha \in]0, 1[$. Então podemos escrever

$$\begin{aligned} \|y_x - x\|^2 &\leq \|y_x + \alpha(y - y_x) - x\|^2 \\ &= \|(y_x - x) + \alpha(y - y_x)\|^2 \\ &= \|y_x - x\|^2 + 2\alpha\langle y_x - x, y - y_x \rangle + \alpha^2\|y - y_x\|^2. \end{aligned}$$

Esta desigualdade implica que

$$0 \leq \alpha\langle y_x - x, y - y_x \rangle + \frac{1}{2}\alpha^2\|y - y_x\|^2.$$

Dividindo por $\alpha > 0$ e fazendo $\alpha \downarrow 0$ obtemos

$$\langle x - y_x, y - y_x \rangle \leq 0. \quad \square$$

Teorema III.2.5. *Existe um único ponto $y_x \in C$ tal que $\|y_x - x\| \leq \|y - x\|$, para todo $y \in C$.*

Demonstração. Suponha que $y_x \in C$ satisfaça $\langle x - y_x, y - y_x \rangle \leq 0$, para todo $y \in C$. Se $x \in C$, então o resultado vale. Se não, escreva para um arbitrário $y \in C$

$$\begin{aligned} 0 &\geq \langle x - y_x, y - y_x \rangle \\ &= \langle x - y_x, y - x + x - y_x \rangle \\ &= \|x - y_x\|^2 + \langle x - y_x, y - x \rangle \\ &\geq \|y_x - x\|^2 - \|y_x - x\| \|y - x\|, \end{aligned}$$

onde a desigualdade de *Cauchy-Schwarz* foi utilizada. Dividindo por $\|y_x - x\| > 0$, obtemos $\|y_x - x\| \leq \|y - x\|$. Agora, suponhamos que existam $y_x \in C$ e $y'_x \in C$ tais que

$$\|y_x - x\| \leq \|y - x\| \quad \text{e} \quad \|y'_x - x\| \leq \|y - x\|,$$

para todo $y \in C$. Em particular, valem as desigualdades

$$\langle x - y_x, y'_x - y_x \rangle \leq 0 \quad \text{e} \quad \langle x - y'_x, y_x - y'_x \rangle \leq 0,$$

e somando-as obtemos

$$\langle y'_x - y_x, y'_x - y_x \rangle \leq 0.$$

Logo, $y'_x = y_x$. Portanto tal ponto y_x é único. \square

Denotemos por $p_C(x)$ o único ponto dado pelo teorema anterior, que é chamado de *projeção* de x sobre o convexo C .

Teorema III.2.6. *Seja $C \subset \mathbb{R}^n$ um conjunto não vazio convexo fechado, e seja $x \notin C$. Então existe $s \in \mathbb{R}^n$ tal que*

$$\langle s, x \rangle > \sup\{\langle s, y \rangle : y \in C\}. \quad (\text{III.2.3})$$

Demonstração. Seja $s := x - p_C(x) \neq 0$. Escrevemos (III.2.2) como

$$0 \geq \langle s, y - x + s \rangle = \langle s, y \rangle - \langle s, x \rangle + \|s\|^2.$$

Assim,

$$\langle s, x \rangle - \|s\|^2 \geq \langle s, y \rangle,$$

para todo $y \in C$. Segue da última desigualdade que $s = x - p_C(x)$ satisfaz (III.2.3). \square

Lema III.2.7. *Seja $x \in \partial C$, onde $C \neq \emptyset$ é convexo em \mathbb{R}^n (naturalmente $C \neq \mathbb{R}^n$). Então existe um hiperplano suporte a C em x .*

Demonstração. Como C , o fecho de C e seus complementos possuem a mesma fronteira, uma seqüência $\{x_k\}$ pode ser encontrada tal que x_k não pertença ao fecho de C , para $k = 1, 2, \dots$ e $\lim_{k \rightarrow +\infty} x_k = x$. Para cada k temos, pelo Teorema III.2.6, algum s_k com $\|s_k\| = 1$ tal que $\langle s_k, x_k - y \rangle > 0$, para todo y pertencente a C . Extraindo uma subsequência, se necessário, temos que $s_k \rightarrow s$ (observe que $s \neq 0$) e passando ao limite obtemos

$$\langle s, x - y \rangle \geq 0,$$

para todo $y \in C$. Tomando $r = \langle s, x \rangle$ o hiperplano $H_{s,r} = \{y \in \mathbb{R}^n; \langle s, y \rangle = r\}$ é suporte a C em x . \square

Na próxima seção, faremos um estudo detalhado dos resultados de funções convexas que utilizaremos adiante.

III.3 Funções convexas

Uma importante classe de funções, no contexto da análise real, é a classe das funções convexas. A noção de convexidade ocupa posição de destaque no estudo da teoria de otimização. A atratividade da convexidade para resolver problemas de minimização reside no fato de que a determinação de um mínimo local de uma função convexa implica na determinação de um mínimo global dessa função. Além disso, a estrita convexidade de uma função definida num conjunto compacto permitirá escrevermos de maneira única a iteração de ponto proximal que será estudada no capítulo seguinte.

Definição III.3.1. Seja $C \subset \mathbb{R}^n$ um conjunto convexo não vazio. Uma função $f: C \rightarrow \mathbb{R}$ é dita *convexa* sobre C quando, para todo par $(x, x') \in C \times C$ e todo $\alpha \in]0, 1[$, vale

$$f(\alpha x + (1 - \alpha)x') \leq \alpha f(x) + (1 - \alpha)f(x'). \quad (\text{III.3.1})$$

Dizemos que f é *estritamente convexa* sobre C quando (III.3.1) vale como uma desigualdade estrita se $x \neq x'$.

Exemplo III.3.2. A função $h(x) = \lambda_k \|x_k - x\|^2$, $\lambda_k > 0$, é estritamente convexa, para todo $k > 0$.

Proposição III.3.3. Se $f: \mathbb{R}^n \rightarrow \mathbb{R}$ 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. Se x' e x'' pertencem a \mathbb{R}^n e $0 \leq \alpha \leq 1$, vale:

$$\begin{aligned} f(\alpha x' + [1 - \alpha]x'') &\leq \alpha f(x') + [1 - \alpha]f(x'') \quad \text{e} \\ h(\alpha x' + [1 - \alpha]x'') &< \alpha h(x') + [1 - \alpha]h(x''). \end{aligned}$$

Logo,

$$\begin{aligned}
(f+h)(\alpha x' + [1-\alpha]x'') &= f(\alpha x' + [1-\alpha]x'') + h(\alpha x' + [1-\alpha]x'') \\
&\leq \alpha f(x') + [1-\alpha]f(x'') + h(\alpha x' + [1-\alpha]x'') \\
&< \alpha f(x') + [1-\alpha]f(x'') + \alpha h(x') + [1-\alpha]h(x'') \\
&= \alpha(f+h)(x') + [1-\alpha](f+h)(x'').
\end{aligned}$$

Assim, $(f+h)$ é estritamente convexa em \mathbb{R}^n . \square

É fácil verificar que o epigráfico de uma função convexa $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é um conjunto convexo. Este fato, juntamente com os resultados obtidos na seção anterior, será importante na demonstração do próximo teorema: a existência de uma função afim minorando f .

Teorema III.3.4. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. Para todo $x \in \mathbb{R}^n$, existe $s = s(x) \in \mathbb{R}^n$ tal que*

$$f(y) \geq f(x) + \langle s, y - x \rangle,$$

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

Demonstração. Sabemos que $\text{epi } f = \{(x, r) \in \mathbb{R}^n \times \mathbb{R} : r \geq f(x)\}$ é um subconjunto convexo fechado de $\mathbb{R}^n \times \mathbb{R}$. Dado $x \in \mathbb{R}^n$ e $(x, f(x)) \in \partial(\text{epi } f)$, podemos tomar, pelo Lema III.2.7, um hiperplano suporte ao $\text{epi } f$ em $(x, f(x))$. Usando (III.2.3), existem $s \in \mathbb{R}^n$ e $\alpha \in \mathbb{R}$, ambos não nulos, tais que

$$\langle s, y \rangle + \alpha r \leq \langle s, x \rangle + \alpha f(x), \tag{III.3.2}$$

para todo $(y, r) \in \mathbb{R}^n \times \mathbb{R}$. Escolha $r \in \mathbb{R}$ e $\delta > 0$, tais que $f(x + \delta s) < r$. Assim, de (III.3.2), temos

$$\begin{aligned}
0 &\geq \langle s, \delta s \rangle + \alpha(f(x + \delta s) - f(x)), \\
0 &< \delta \|s\|^2 \leq \alpha(f(x) - f(x + \delta s)).
\end{aligned}$$

Isto mostra que $\alpha \neq 0$ (senão s também seria igual a zero). Sem perda de generalidade, podemos assumir $\alpha = -1$ e, retornando à inequação (III.3.2), obtemos

$$\langle s, y \rangle - r \leq \langle s, x \rangle - f(x) \Leftrightarrow f(y) \geq f(x) + \langle s, y - x \rangle,$$

que dá a função afim procurada. □

Como nosso objetivo é resolver um problema de minimização convexa, formalizaremos a definição de mínimo de uma função e demonstraremos os resultados que serão necessários na prova de convergência do algoritmo.

Definição III.3.5. Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função qualquer. Um ponto $x_* \in \mathbb{R}^n$ é:

(i) um *mínimo local* de f se existe $r > 0$ tal que: $\|x - x_*\| \leq r$ implica $f(x_*) \leq f(x)$, para todo $x \in B(x_*; r)$.

(ii) um *mínimo global* de f se $f(x_*) \leq f(x)$, para todo $x \in \mathbb{R}^n$.

Proposição III.3.6. *Sejam $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa e x_* um mínimo local de f em \mathbb{R}^n . Então x_* é mínimo global de f em \mathbb{R}^n .*

Demonstração. Suponhamos que f admita um mínimo local x_* que não é mínimo global. Sendo x_* um mínimo local, existe $r > 0$ tal que $f(x_*) \leq f(x)$, para todo $x \in B(x_*; r)$. Como x_* não é mínimo global, existe $z \in \mathbb{R}^n$ tal que $f(z) < f(x_*)$. Sendo \mathbb{R}^n convexo, $(\lambda x_* + (1 - \lambda)z) \in \mathbb{R}^n$, para todo $\lambda \in]0, 1[$. Escolha λ suficientemente próximo da unidade tal que $(\lambda x_* + (1 - \lambda)z) \in B(x_*; r)$. Pela convexidade de f , temos

$$f(\lambda x_* + (1 - \lambda)z) \leq \lambda f(x_*) + (1 - \lambda)f(z) < f(x_*),$$

pois $f(z) < f(x_*)$. Mas, pela construção, $(\lambda x_* + (1 - \lambda)z)$ está na bola $B(x_*; r)$. Logo $f(x_*) \leq f(\lambda x_* + (1 - \lambda)z)$, uma contradição. Portanto, x_* é um mínimo global de f em \mathbb{R}^n . □

A seguir definiremos coercividade de uma função contínua $f: \mathbb{R}^n \rightarrow \mathbb{R}$. Uma implicação particular desta definição é o Teorema III.3.8: se uma função contínua f possui a propriedade de coercividade então f possui pelo menos um mínimo global. Este teorema será importante para a boa definição do algoritmo de ponto proximal para funções convexas.

Definição III.3.7. Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função contínua. Diz-se que f é *1-coerciva* se

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

A definição acima diz que f tende ao infinito mais rápido do que qualquer função afim.

Teorema III.3.8. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função contínua. Se f é 1-coerciva, então f possui pelo menos um mínimo global.*

Demonstração. Por hipótese $\lim_{\|x\| \rightarrow +\infty} \frac{f(x)}{\|x\|} = +\infty$. Isto significa que se $\|x\|$ é grande, então $\frac{f(x)}{\|x\|}$ também o é. Conseqüentemente, dado $M \geq 0$ existe um número $r > 0$ tal que $\|x\| \geq r$ implica que

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

Seja $\overline{B}(0; r)$ o conjunto $\{x : \|x\| \leq r\}$. A função f é contínua em cada ponto do conjunto $\overline{B}(0; r)$, e este conjunto é fechado e limitado. Pelo Teorema de *Weierstrass*, segue que f atinge um valor mínimo sobre $\overline{B}(0; r)$ num ponto $x_* \in \overline{B}(0; r)$; ou seja, $x \in \overline{B}(0; r)$ implica $f(x_*) \leq f(x)$. Em particular, como $0 \in \overline{B}(0; r)$, vemos que $f(x_*) \leq f(0)$. Por outro lado, se $x \notin \overline{B}(0; r)$, então $f(x) > f(0) \geq f(x_*)$. Resumindo, vemos que $x \in \overline{B}(0; r)$ implica $f(x) \geq f(x_*)$ e $x \notin \overline{B}(0; r)$ implica $f(x) > f(x_*)$. Isto mostra que x_* é um mínimo global de f . \square

Teorema III.3.9. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. Então, para toda coleção de pontos $\{x_1, x_2, \dots, x_k\}$ em \mathbb{R}^n e toda coleção $\{\alpha_1, \alpha_2, \dots, \alpha_k\}$ em \mathbb{R}^n satisfazendo*

$$\alpha_i \geq 0 \quad \text{para } i = 1, 2, \dots, k \quad \text{e} \quad \sum_{i=1}^k \alpha_i = 1,$$

vale a desigualdade de Jensen

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

Demonstração. Considere primeiro $k = 2$. A relação é trivial se α_1 ou α_2 são zero. Caso contrário, a convexidade da função f resulta em $f(\alpha_1 x_1 + \alpha_2 x_2) \leq \alpha_1 f(x_1) + \alpha_2 f(x_2)$. Ou seja, $f(\sum_{i=1}^2 \alpha_i x_i) \leq \sum_{i=1}^2 \alpha_i f(x_i)$. Agora, suponha indutivamente que a relação é verdadeira para $k - 1$ e considere as coleções $\{x_i\}$ e $\{\alpha_i\}$, com $\alpha_i \geq 0$ para $i = 1, 2, \dots, k$ e $\sum_{i=1}^k \alpha_i = 1$. Se α_k é 0 ou 1, então nada há para provar. Se não, fixe $\bar{\alpha} := \sum_{i=1}^{k-1} \alpha_i$ e $\bar{\alpha}_i := \frac{\alpha_i}{\bar{\alpha}}$ para $i = 1, \dots, k - 1$. Observe que $\alpha_k = 1 - \bar{\alpha} \in]0, 1[$, $\bar{\alpha}_i \geq 0$ e $\sum_{i=1}^{k-1} \bar{\alpha}_i = 1$. Assim,

$$\sum_{i=1}^k \alpha_i x_i = \bar{\alpha} \sum_{i=1}^{k-1} \bar{\alpha}_i x_i + (1 - \bar{\alpha}) x_k.$$

O ponto $\bar{x} := \sum_{i=1}^{k-1} \bar{\alpha}_i x_i$ da última relação acima pertence a \mathbb{R}^n . Usando a convexidade de f e aplicando a hipótese de indução para \bar{x} , temos $f(\bar{\alpha} \bar{x} + (1 - \bar{\alpha}) x_k) \leq \bar{\alpha} f(\bar{x}) + (1 - \bar{\alpha}) f(x_k)$.

Ou seja,

$$\begin{aligned} f\left(\sum_{i=1}^k \alpha_i x_i\right) &\leq \bar{\alpha} f\left(\sum_{i=1}^{k-1} \bar{\alpha}_i x_i\right) + \alpha_k f(x_k) = f\left(\sum_{i=1}^{k-1} \alpha_i x_i\right) + \alpha_k f(x_k) \\ &\leq \sum_{i=1}^{k-1} \alpha_i f(x_i) + \alpha_k f(x_k) = \sum_{i=1}^k \alpha_i f(x_i). \quad \square \end{aligned}$$

Definição III.3.10. Diz-se que uma função $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é *localmente limitada* quando para todo $x_0 \in \mathbb{R}^n$ existem $c > 0$ e $\delta > 0$, tais que $|f(x)| \leq c$, para todo $x \in B(x_0; \delta)$.

Teorema III.3.11. Se $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa, então f é localmente limitada.

Demonstração. Dado $x_0 \in \mathbb{R}^n$, tome um “cubo” C em \mathbb{R}^n , de vértices x_1, x_2, \dots, x_m ($m = 2^n$) e com centro em x_0 . Como o “cubo” C é um conjunto convexo em \mathbb{R}^n , para todo ponto $x \in C$, podemos encontrar escalares $\lambda_1, \lambda_2, \dots, \lambda_m$, tais que

$$x = \sum_{i=1}^m \lambda_i x_i, \quad \text{com } \lambda_i \geq 0 \quad \text{e} \quad \sum_{i=1}^m \lambda_i = 1.$$

Sendo f uma função convexa vale a desigualdade de *Jensen*:

$$f(x) \leq \sum_{i=1}^m \lambda_i f(x_i) \leq \max_{1 \leq i \leq m} f(x_i) := \tilde{c}.$$

Assim, f é limitada superiormente. Por outro lado, para qualquer $x \in C$, podemos escolher $y \in C$, tal que $x_0 = \frac{1}{2}x + \frac{1}{2}y$. Então $f(x_0) \leq \frac{1}{2}f(x) + \frac{1}{2}f(y)$. Mas isso implica

$$f(x) \geq 2[f(x_0) - \frac{1}{2}f(y)] \geq 2f(x_0) - \tilde{c}.$$

Logo f é também limitada inferiormente em C . Portanto, f é localmente limitada. \square

Teorema III.3.12. Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa e suponha existirem $x_0, \delta > 0, m$ e M , tais que $m \leq f(x) \leq M$, para todo $x \in B(x_0; 2\delta)$. Então f é lipschitziana em $B(x_0; \delta)$.

Demonstração. Para os pontos y e y' pertencentes à $B(x_0; \delta)$, com $y \neq y'$, tome

$$y'' := y' + \delta \frac{y' - y}{\|y' - y\|} \in B(x_0; 2\delta).$$

Observe que y' pertence ao segmento $[y, y'']$, isto é, $y' = \frac{\|y' - y\|}{\delta + \|y' - y\|} y'' + \frac{\delta}{\delta + \|y' - y\|} y$.

Aplicando a convexidade de f , obtemos

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

Subtraindo $f(y)$ de ambos os lados da desigualdade, resulta

$$f(y') - f(y) \leq \frac{\|y' - y\|}{\delta + \|y' - y\|} f(y'') + \left(\frac{\delta}{\delta + \|y' - y\|} - 1 \right) f(y) = \frac{\|y' - y\|}{\delta + \|y' - y\|} [f(y'') - f(y)].$$

Como $m \leq f(y'') \leq M$ e $m \leq f(y') \leq M$, temos que $f(y'') \leq M$ e $-f(y') \leq -m$.

Daí

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

Assim,

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

Como y e y' são quaisquer obtemos a desigualdade análoga trocando y por y' . Portanto,

$$|f(y') - f(y)| \leq \frac{M - m}{\delta} \|y' - y\|. \quad \square$$

Corolário III.3.13. *Se $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é uma função convexa, então f é localmente lipschitziana.*

Demonstração. Aplicação imediata dos teoremas III.3.11 e III.3.12. □

Teorema III.3.14. *Se $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa, então f é contínua.*

Demonstração. Dado $x_0 \in \mathbb{R}^n$, existem, pelo Corolário III.3.13, $\delta_{x_0} > 0$ e $L_{x_0} > 0$, tais que para todo $x, y \in B(x_0; \delta_{x_0})$ implica $|f(x) - f(y)| \leq L_{x_0} \|x - y\|$. Dado $\epsilon > 0$, tome $\delta = \min\{\frac{\epsilon}{L_{x_0}}, \delta_{x_0}\}$. Logo, para todo $x \in B(x_0; \delta) \subset B(x_0; \delta_{x_0})$, temos

$$|f(x) - f(x_0)| \leq L_{x_0} \|x - x_0\| \leq L_{x_0} \cdot \frac{\epsilon}{L_{x_0}} = \epsilon.$$

Portanto, f é contínua. □

Neste trabalho a função objetivo $f: \mathbb{R}^n \rightarrow \mathbb{R}$ não é necessariamente diferenciável. Mas, sendo uma função convexa, f é “subdiferenciável”. Dado $x \in \mathbb{R}^n$, o conjunto de todos os vetores $s \in \mathbb{R}^n$ satisfazendo (III.3.4) ou (III.3.5) é chamado o *subdiferencial* de f em x e denotado por $\partial f(x)$. As definições a seguir conduzem a duas interpretações do subdiferencial.

Definição III.3.15. Seja S um conjunto não vazio em \mathbb{R}^n . A função

$$\begin{aligned}\sigma_S: \mathbb{R}^n &\rightarrow \mathbb{R} \\ x &\mapsto \sigma_S(x) := \sup\{\langle s, x \rangle : s \in S\}\end{aligned}$$

é chamada *função suporte* de S .

Definição III.3.16. A *derivada direcional* de f em x na direção d é

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

Quando f é uma função convexa a igualdade acima pode ser substituída por

$$f'(x, d) = \inf_{t > 0} \frac{f(x + td) - f(x)}{t}. \quad (\text{III.3.3})$$

Definição III.3.17. (Subdiferencial I) O *subdiferencial* $\partial f(x)$ de f em x é o conjunto cuja função suporte é $f'(x, \cdot)$, isto é,

$$\partial f(x) := \{s \in \mathbb{R}^n : \langle s, d \rangle \leq f'(x, d) \text{ para todo } d \in \mathbb{R}^n\}. \quad (\text{III.3.4})$$

Nesta definição de subdiferencial está envolvido o cálculo da derivada direcional e determinação de uma função suporte. É possível dar uma definição mais direta:

Definição III.3.18. (Subdiferencial II) O *subdiferencial* de f em x é o conjunto dos vetores $s \in \mathbb{R}^n$ satisfazendo

$$f(y) \geq f(x) + \langle s, y - x \rangle, \quad (\text{III.3.5})$$

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

Um vetor $s \in \mathbb{R}^n$ satisfazendo (III.3.4) ou (III.3.5) é dito um *subgradiente* de f no ponto x . A multifunção $\partial f: x \mapsto \partial f(x)$ é chamada o *subdiferencial* de f .

Teorema III.3.19. *As definições III.3.17 e III.3.18 são equivalentes.*

Demonstração. Seja s satisfazendo (III.3.4), isto é

$$\langle s, d \rangle \leq f'(x, d), \quad (\text{III.3.6})$$

para todo $d \in \mathbb{R}^n$. A equação (III.3.3) é equivalente a

$$\langle s, d \rangle \leq \frac{f(x + td) - f(x)}{t}, \quad (\text{III.3.7})$$

para todo $d \in \mathbb{R}^n$ e $t > 0$. Quando d percorre \mathbb{R}^n e t percorre \mathbb{R}_+ , $y := x + td$ percorre \mathbb{R}^n e então vemos que (III.3.7) é exatamente (III.3.5). \square

Proposição III.3.20. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. O conjunto $\partial f(x)$ é não vazio, convexo e compacto, para todo $x \in \mathbb{R}^n$.*

Demonstração. Seja $x \in \mathbb{R}^n$. Juntando os resultados do Teorema III.3.4 e da Definição III.3.18 segue imediatamente que $\partial f(x) \neq \emptyset$. Agora, sejam $s, w \in \partial f(x)$ e $t \in [0, 1]$. Mostraremos que $(1 - t)s + tw \in \partial f(x)$. Novamente, pela Definição III.3.18, valem as desigualdades

$$f(x) + \langle s, y - x \rangle \leq f(y) \quad \text{e} \quad f(x) + \langle w, y - x \rangle \leq f(y),$$

para todo $y \in \mathbb{R}^n$. Logo,

$$\begin{aligned} f(x) + \langle (1 - t)s + tw, y - x \rangle &= f(x) + (1 - t)\langle s, y - x \rangle + t\langle w, y - x \rangle \\ &= f(x) - tf(x) + tf(x) + (1 - t)\langle s, y - x \rangle + t\langle w, y - x \rangle \\ &= (1 - t)[f(x) + \langle s, y - x \rangle] + t[f(x) + \langle w, y - x \rangle] \\ &\leq (1 - t)f(y) + tf(y) \\ &= f(y). \end{aligned}$$

Portanto, $\partial f(x)$ é convexo. Para a última afirmação do teorema mostraremos que $\partial f(x)$ é fechado e limitado. Seja $\{s_k\}$ uma seqüência em $\partial f(x)$ convergindo para $s \in \mathbb{R}^n$. Para todo $k \in \mathbb{N}$, temos

$$f(y) \geq f(x_k) + \langle s_k, y - x_k \rangle,$$

para todo $y \in \mathbb{R}^n$. Passando ao limite quando k tende a $+\infty$ e usando a continuidade de f e do produto escalar, obtemos

$$f(y) \geq f(x) + \langle s, y - x \rangle,$$

para todo $y \in \mathbb{R}^n$. Logo $s \in \partial f(x)$, o que significa que $\partial f(x)$ é fechado. Para finalizar, dado $s \in \partial f(x)$, $s \neq 0$, tomemos $\delta > 0$ arbitrariamente pequeno de modo que $y = x + \delta \frac{s}{\|s\|}$ pertença ao conjunto compacto $\overline{B}(x; \delta)$. Sendo f convexa, para todo $y \in \overline{B}(x; \delta)$, existe uma constante de Lipschitz $L > 0$ tal que $f(y) - f(x) \leq L\|y - x\|$. Ou seja,

$$f(y) - f(x) \leq L\delta, \tag{III.3.8}$$

para todo $y \in \overline{B}(x; \delta)$. Por outro lado, pela convexidade de f , $f(y) \geq f(x) + \langle s, y - x \rangle$, para todo $y \in \mathbb{R}^n$. Substituindo pelo y dado acima obtemos $f(y) \geq f(x) + \langle s, \delta \frac{s}{\|s\|} \rangle$, o que implica

$$f(y) \geq f(x) + \delta\|s\|. \tag{III.3.9}$$

Juntando (III.3.8) e (III.3.9) obtemos $\delta\|s\| \leq f(y) - f(x) \leq L\delta$ o que resulta $\|s\| \leq L$. Assim, $\partial f(x)$ é limitado. Portanto $\partial f(x)$ é compacto. \square

Se uma função f é diferenciável em x , então o conjunto $\partial f(x)$ reduz-se ao gradiente $\nabla f(x)$. O próximo teorema será utilizado na demonstração da Proposição V.2.2 no Capítulo V.

Teorema III.3.21. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável. Então f é convexa se, e somente se,*

$$f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle \quad (\text{III.3.10})$$

para todo x e todo y em \mathbb{R}^n .

Demonstração. Seja f uma função convexa; para $(x, y) \in \mathbb{R}^n \times \mathbb{R}^n$ e $\alpha \in]0, 1[$ arbitrário temos, da definição de convexidade:

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

Observando que $\alpha y + (1 - \alpha)x = x + \alpha(y - x)$, dividindo por α e fazendo $\alpha \downarrow 0$, o lado direito da igualdade acima tende a $\langle \nabla f(x), y - x \rangle$. Logo (III.3.10) está verificada. Reciprocamente, tome x_1 e x_2 em \mathbb{R}^n , $\alpha \in]0, 1[$ e defina $x := \alpha x_1 + (1 - \alpha)x_2 \in \mathbb{R}^n$. Por hipótese, $f(x_i) \geq f(x) + \langle \nabla f(x), x_i - x \rangle$, para $i = 1, 2$. Usando combinação convexa, obtemos

$$\alpha f(x_1) + (1 - \alpha)f(x_2) \geq f(x) + \langle \nabla f(x), \alpha x_1 + (1 - \alpha)x_2 - x \rangle,$$

o qual, após simplificação, resulta em $\alpha f(x_1) + (1 - \alpha)f(x_2) \geq f(\alpha x_1 + (1 - \alpha)x_2)$. \square

O próximo resultado é elementar. Combinando-o com o Teorema III.3.26 poderemos, no capítulo seguinte, caracterizar a seqüência gerada pelo algoritmo de ponto proximal.

Teorema III.3.22. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. O ponto $x_* \in \mathbb{R}^n$ é um mínimo de f , isto é, $f(x_*) \leq f(x)$ para todo $x \in \mathbb{R}^n$ se, e somente se $0 \in \partial f(x_*)$.*

Demonstração. A equivalência segue imediatamente da inequação (III.3.5), pois:

$$f(x) \geq f(x_*) \Leftrightarrow f(x) \geq f(x_*) + \langle 0, x - x_* \rangle$$

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

Proposição III.3.23. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. O conjunto dos minimizadores de f é convexo.*

Demonstração. Seja U^* o conjunto dos minimizadores da função convexa f . Dados $x_1, x_2 \in U^*$, temos $f(x_1) = f(x_2)$. Para $\alpha \in [0, 1]$, queremos mostrar que $x = \alpha x_1 + (1 - \alpha)x_2$ também é um minimizador de f . Pela convexidade de f temos

$$f(x) = f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2) = f(x_1).$$

Mas isto deve valer como igualdade, ou x_1 e x_2 não seriam minimizadores de f . Logo, $x \in U^*$. Portanto, U^* é um conjunto convexo. \square

Proposição III.3.24. *Se $f: K \rightarrow \mathbb{R}$ é estritamente convexa sobre o conjunto compacto $K \subset \mathbb{R}^n$, então f possui um único minimizador.*

Demonstração. Como f está definida sobre um conjunto compacto $K \subset \mathbb{R}^n$, pelo Teorema de Weierstrass, f atinge seu mínimo. Suponhamos, por absurdo, que $x_* \in K$, $x_{**} \in K$ e $x_* \neq x_{**}$ sejam minimizadores da função estritamente convexa f . Sejam $s \in \partial f(x_{**})$ e $s' \in \partial f(x_*)$, então:

$$\begin{aligned} f(x_*) &> f(x_{**}) + \langle s, x_* - x_{**} \rangle \quad \text{e} \\ f(x_{**}) &> f(x_*) + \langle s', x_{**} - x_* \rangle. \end{aligned}$$

Mas, pelo Teorema III.3.22, para $s = s' = 0$, obtemos

$$f(x_*) > f(x_{**}) \quad \text{e} \quad f(x_{**}) > f(x_*).$$

Portanto, f possui um único minimizador. \square

Tomando $f: \mathbb{R}^n \rightarrow \mathbb{R}$ estritamente convexa, se o conjunto U^* dos minimizadores de f é não vazio, então f possui um único minimizador.

Proposição III.3.25. *Sejam f e g funções convexas de \mathbb{R}^n em \mathbb{R} e $\sigma_{\partial f}$ e $\sigma_{\partial g}$ as funções suportes dos conjuntos convexos fechados ∂f e ∂g . Então $\sigma_{\partial f} + \sigma_{\partial g}$ é a função suporte de $\partial f + \partial g$.*

Demonstração. Chamemos ∂h o conjunto fechado $\partial f + \partial g$. Pela Definição III.3.15 de função suporte:

$$\sigma_{\partial h}(d) = \sup\{\langle s_1 + s_2, d \rangle : s_1 \in \partial f \text{ e } s_2 \in \partial g\}.$$

Na expressão acima, s_1 e s_2 percorrem de forma independente os conjuntos ∂f e ∂g , respectivamente. Assim,

$$\sigma_{\partial h}(d) = \sup_{s \in \partial f} \langle s, d \rangle + \sup_{s \in \partial g} \langle s, d \rangle. \quad \square$$

Teorema III.3.26. *Sejam f e g funções convexas de \mathbb{R}^n em \mathbb{R} . Então $\partial(f + g)(x) = \partial f(x) + \partial g(x)$, para todo $x \in \mathbb{R}^n$.*

Demonstração. Pela Proposição III.3.25 temos que $\partial f(x) + \partial g(x)$ é um conjunto convexo compacto cuja função suporte é

$$f'(x, \cdot) + g'(x, \cdot).$$

Por outro lado, a função suporte de $\partial(f + g)(x)$ é, pela definição de derivada direcional,

$$(f + g)'(x, \cdot)$$

que, de um cálculo elementar, é justamente $f'(x, \cdot) + g'(x, \cdot)$. Portanto, os dois conjuntos convexos e compactos $\partial(f + g)(x)$ e $\partial f(x) + \partial g(x)$ coincidem, pois têm a mesma função suporte. \square

No Capítulo VI desenvolveremos o algoritmo de ponto proximal para operadores monótonos maximais arbitrários, $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$. Um problema fundamental é determinar um elemento $z \in \mathbb{R}^n$ tal que $0 \in T(z)$. Agora, se T é o subdiferencial ∂f de uma função

convexa $f: \mathbb{R}^n \rightarrow \mathbb{R}$, então T é monótono maximal, e a relação $0 \in T(z)$ quer dizer que z é um minimizador de f , como já vimos no Teorema III.3.22. Neste sentido, o problema de encontrar uma singularidade de um operador monótono maximal generaliza o problema de minimizar uma função convexa. Para demonstrarmos que o operador ∂f é monótono maximal, faz-se necessário algumas definições, e começaremos por definir convexidade *própria*.

Definição III.3.27. A função $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$, não identicamente $+\infty$, é dita *convexa* quando, para todo $(x, x') \in \mathbb{R}^n \times \mathbb{R}^n$ e todo $\alpha \in]0, 1[$, vale

$$f(\alpha x + (1 - \alpha)x') \leq \alpha f(x) + (1 - \alpha)f(x'),$$

considerada como uma desigualdade em $\mathbb{R} \cup \{+\infty\}$.

Para compreender a definição acima lembremo-nos da Definição III.3.1: uma função $f: C \rightarrow \mathbb{R}$, é dita *convexa* sobre o conjunto convexo $\emptyset \neq C \subset \mathbb{R}^n$ quando, para todo par $(x, x') \in C \times C$ e todo $\alpha \in]0, 1[$, vale

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

Então estendemos a função f , fazendo

$$f(x) := +\infty,$$

para $x \notin C$. Assim, obtemos uma nova função f , que chamaremos de função convexa *própria*.

Definição III.3.28. Seja $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ uma função convexa, $f \not\equiv +\infty$. A função $f^*: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ definida por:

$$f^*(s) = \sup_{x \in \mathbb{R}^n} \{\langle x, s \rangle - f(x)\},$$

para todo $s \in \mathbb{R}^n$, é dita a *conjugada* da função f .

Exemplo III.3.29. Dada a função convexa $f(x) = \|x\|$, encontremos sua função conjugada. Calculando o subdiferencial de f obtemos: $\partial f(x) = \{1\}$, se $x > 0$, $\partial f(x) = [-1, 1]$, se $x = 0$ e $\partial f(x) = \{-1\}$, se $x < 0$. Pela definição de conjugada, para todo $s \in \partial f(x)$, $f^*(s)$ é o $\sup \{\langle s, x \rangle - f(x)\}$, $x \in \mathbb{R}^n$. Logo, $f^*(s) = \sup_{x \in \mathbb{R}^n} \{(s-1)x\}$, se $x \geq 0$ e $f^*(s) = \sup_{x \in \mathbb{R}^n} \{(s+1)x\}$, se $x < 0$. Portanto,

$$f^*(s) = \begin{cases} +\infty, & \text{se } \|s\| > 1 \\ 0, & \text{se } \|s\| \leq 1 \end{cases}.$$

Observação III.3.30. Seja $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$. Para cada $x \in \mathbb{R}^n$ e cada $s \in \mathbb{R}^n$, vale, pela Definição III.3.28, que $f^*(s) \geq \langle x, s \rangle - f(x)$; isto é,

$$f(x) + f^*(s) \geq \langle x, s \rangle,$$

sempre que o lado esquerdo da desigualdade estiver definido. Esta é chamada a *desigualdade de Fenchel*.

Teorema III.3.31. *Sejam $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ convexa, $f \not\equiv +\infty$, e $x \in \mathbb{R}^n$. Então $s \in \partial f(x)$ se, e somente se, $f^*(s) = \langle x, s \rangle - f(x)$.*

Demonstração. Seja s um subgradiente de f em x . Então, $f(y) \geq f(x) + \langle s, y - x \rangle$, para todo $y \in \mathbb{R}^n$. Mas isso equivale a $\langle y, s \rangle - f(y) \leq \langle x, s \rangle - f(x)$, para todo $y \in \mathbb{R}^n$. Como $f^*(s) = \sup_{y \in \mathbb{R}^n} \{\langle y, s \rangle - f(y)\} \leq \langle x, s \rangle - f(x)$, obtemos que $f^*(s) = \langle x, s \rangle - f(x)$. Reciprocamente, se $f^*(s) = \sup_{y \in \mathbb{R}^n} \{\langle y, s \rangle - f(y)\} = \langle x, s \rangle - f(x)$, então $f^*(s) < +\infty$. Ou seja $\langle x, s \rangle - f(x) \geq \langle y, s \rangle - f(y)$, para todo $y \in \mathbb{R}^n$. Logo, $f(y) \geq f(x) + \langle y - x, s \rangle$, para todo $y \in \mathbb{R}^n$. Portanto, $s \in \partial f(x)$. \square

Observe que este teorema revela que se $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é uma função convexa e $s \in \partial f(x)$, para algum $x \in \mathbb{R}^n$, então $f^*(s) < +\infty$.

Teorema III.3.32. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ uma função convexa, $f \not\equiv +\infty$. A conjugada $f^*: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ é uma função convexa.*

Demonstração. Dados s e $s' \in \mathbb{R}^n$, consideremos dois casos. Primeiro, $s, s' \in \mathbb{R}^n$ tais que $f^*(s) < +\infty$ e $f^*(s') < +\infty$. Para $t \in [0, 1]$,

$$\begin{aligned} f^*[(1-t)s + ts'] &= \sup_{x \in \mathbb{R}^n} \{(1-t)\langle s, x \rangle + t\langle s', x \rangle - f(x)\} \\ &= \sup\{(1-t)\langle s, x \rangle - (1-t)f(x)\} + \sup\{t\langle s', x \rangle - tf(x)\} \\ &\leq (1-t)f^*(s) + tf^*(s'). \end{aligned}$$

Logo, neste caso, f^* é convexa. Agora consideremos $s, s' \in \mathbb{R}^n$ tais que $f^*(s) = +\infty$ ou $f^*(s') = +\infty$. Trivialmente temos: $f^*[(1-t)s + ts'] \leq (1-t)f^*(s) + tf^*(s')$. Portanto, f^* é uma função convexa. \square

Definição III.3.33. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ uma função convexa. Dizemos que a função $f^{**}: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ é a função conjugada $(f^*)^*$ da conjugada de f .*

Lema III.3.34. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ uma função convexa. Então f^{**} é o supremo do conjunto de todas as funções afins que minoram f .*

Demonstração. Seja A o conjunto de todas as funções afins que minoram f e considere $\mathcal{F} = \sup\{g : g \in A\}$. Para cada $s \in \mathbb{R}^n$, a função

$$g(x) = \langle x, s \rangle - f^*(s),$$

é uma função afim. Da Observação III.3.30 segue que g é uma minorante de f . Logo $g \in A$. Daí

$$f^{**}(x) = \sup_{s \in \mathbb{R}^n} \{\langle x, s \rangle - f^*(s)\} \leq \mathcal{F}(x), \quad (\text{III.3.11})$$

para todo $x \in \mathbb{R}^n$. Se $h \in A$, então h é da forma $h(x) = \langle x, s \rangle - \alpha$, onde $s \in \mathbb{R}^n$ e $\alpha \in \mathbb{R}$, o que implica que, para todo $x \in \mathbb{R}^n$, $\langle x, s \rangle - \alpha \leq f(x)$. Conseqüentemente

$$\alpha \geq \sup_{x \in \mathbb{R}^n} \{\langle x, s \rangle - f(x)\} = f^*(s),$$

e assim

$$h(x) = \langle x, s \rangle - \alpha \leq \langle x, s \rangle - f^*(s).$$

Disto segue que, para cada $x \in \mathbb{R}^n$,

$$\mathcal{F}(x) \leq \sup_{s \in \mathbb{R}^n} \{\langle x, s \rangle - f^*(s)\} = f^{**}(x), \quad (\text{III.3.12})$$

donde, de (III.3.11) e (III.3.12), concluímos que $f^{**} = \mathcal{F}$. □

Proposição III.3.35. *Se $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ é uma função convexa, então $f = f^{**}$.*

Demonstração. Primeiramente, observemos que $f^{**} \leq f$. De fato, por definição

$$f^{**}(w) := \sup\{\langle w, y \rangle - f^*(y) : y \in \mathbb{R}^n\}.$$

Mas $f^*(y) = \sup_{x \in \mathbb{R}^n} \{\langle y, x \rangle - f(x)\} \geq \langle y, w \rangle - f(w)$, para todo $w \in \mathbb{R}^n$, o que implica

$$\langle w, y \rangle - f^*(y) \leq \langle w, y \rangle - (\langle y, w \rangle - f(w)) = f(w).$$

Portanto, $f^{**}(w) \leq f(w)$, para todo $w \in \mathbb{R}^n$. Agora, suponhamos por absurdo, que exista $x_0 \in \mathbb{R}^n$ tal que $f^{**}(x_0) < f(x_0)$. Isto implica a existência de $\alpha \in \mathbb{R}$ tal que $f^{**}(x_0) < \alpha < f(x_0)$. Sendo f convexa, existe uma função afim h minorando f definida por $h(x) = \alpha - \langle s, x - x_0 \rangle$; isto é, $h < f$. Pelo Lema III.3.34 temos $f^{**} > h$ e do fato de $h(x_0) = \alpha$ vem que $f^{**}(x_0) \geq h(x_0) = \alpha$, o que é uma contradição. Portanto $f^{**} = f$. □

CAPÍTULO IV

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

IV.1 Introdução

O *algoritmo de ponto proximal* é um método para minimizar uma função $f: \mathbb{R}^n \rightarrow \mathbb{R}$ convexa, não necessariamente diferenciável, que foi aplicado pela primeira vez em otimização convexa por Martinet [6], entre os anos de 1970 e 1972. A terminologia *ponto proximal* é devida à Rockafellar, conforme a referência [10].

O algoritmo de ponto proximal trata-se de um processo iterativo para minimizar uma função convexa que, a partir de um ponto inicial $x_0 \in \mathbb{R}^n$, gera recursivamente uma seqüência de pontos $\{x_k\} \subset \mathbb{R}^n$ que converge para o minimizador da função objetivo. Uma suposição usual para estabelecer a convergência do algoritmo é a existência de um mínimo da função objetivo; isto é, se existe $x_* \in \mathbb{R}^n$ tal que $f(x_*) \leq f(x)$, para todo $x \in \mathbb{R}^n$, então a seqüência $\{x_k\}$ converge a este minimizador.

Um resultado importante obtido por Osman Güller [2] e apresentado de maneira simples e

unificada por Rafael Correa e Claude Lemaréchal [1], foi a retirada da suposição de existência de um mínimo da função objetivo; ou seja, se a função não possui minimizador, então a seqüência $\{x_k\}$ diverge.

Denotando por U^* o conjunto dos minimizadores da função convexa f , nossa análise de convergência do algoritmo baseia-se na *Fejér convergência* da seqüência $\{x_k\}$ ao conjunto não vazio U^* . No entanto, se U^* é vazio, mostraremos que a seqüência $\{x_k\}$ diverge.

IV.2 Algoritmo de ponto proximal

Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. O *algoritmo de ponto proximal* gera, para um ponto de partida $x_0 \in \mathbb{R}^n$, a seqüência $\{x_k\} \subset \mathbb{R}^n$ pela iteração

$$x_{k+1} := \arg \min_{x \in \mathbb{R}^n} \{f(x) + \lambda_k \|x_k - x\|^2\}, \quad (\text{IV.2.1})$$

onde $\{\lambda_k\}$ é uma seqüência de números positivos.

Definindo

$$f_k(x) := f(x) + \lambda_k \|x_k - x\|^2,$$

nossa primeira preocupação é mostrar que o conjunto $\arg \min_{x \in \mathbb{R}^n} \{f_k(x)\}$ dos minimizadores da função f_k possui um único elemento, pois só assim a fórmula (IV.2.1) faz sentido. Em seguida mostraremos que a seqüência gerada pelo algoritmo converge para o minimizador da função objetivo, caso exista algum.

IV.2.1 Boa definição

Para a boa definição da seqüência $\{x_k\}$, mostraremos que, para todo $k > 0$, a função

$$f_k(x) = f(x) + \lambda_k \|x_k - x\|^2$$

possui um único minimizador. Note que a função f_k é uma regularização aproximada de f , isto é, se f_k possuir minimizador, temos a expectativa de que f_k forneça algum tipo de aproximação ao problema de minimizar a função objetivo f .

Pela Proposição III.3.20, para todo $k > 0$, dado $x_k \in \mathbb{R}^n$, existe $s_k \in \mathbb{R}^n$ tal que $f(x) \geq f(x_k) + \langle s_k, x - x_k \rangle$, e isto implica que

$$f_k(x) = f(x) + \lambda_k \|x_k - x\|^2 \geq f(x_k) + \langle s_k, x - x_k \rangle + \lambda_k \|x_k - x\|^2 .$$

Dividindo 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 passando ao limite, com $\|x - x_k\|$ tendendo a $+\infty$, vem que

$$\lim_{\|x - x_k\| \rightarrow +\infty} \frac{f_k(x)}{\|x - x_k\|} = +\infty .$$

Isto significa que f_k é *1-coerciva* e, pelo Teorema III.3.8, f_k possui pelo menos um minimizador.

É fácil ver que a função $h(x) = \lambda_k \|x_k - x\|^2$ é estritamente convexa. Juntando a isto o resultado da Proposição III.3.3, temos que f_k é uma função estritamente convexa e, portanto, f_k possui um único minimizador. Assim, a seqüência $\{x_k\}$ gerada pela iteração (IV.2.1) está bem definida.

Seja x_{k+1} o único minimizador de f_k . Vale, pelos Teorema III.3.22 e Teorema III.3.26, que

$$0 \in \partial f_k(x_{k+1}) = \partial f(x_{k+1}) + \{2\lambda_k(x_{k+1} - x_k)\},$$

o que equivale dizer

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

Desta forma acabamos de demonstrar o seguinte resultado:

Teorema IV.2.1. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. A seqüência $\{x_k\} \subset \mathbb{R}^n$ gerada por (IV.2.1) está bem definida e caracterizada pela relação*

$$-2\lambda_k(x_{k+1} - x_k) \in \partial f(x_{k+1}). \quad (\text{IV.2.2})$$

IV.2.2 Convergência

Na literatura, até há pouco tempo, os resultados de convergência para o algoritmo de ponto proximal eram obtidos somente para o caso da função convexa possuir minimizador. A demonstração da convergência do algoritmo apresentada aqui, depende somente de alguns conceitos de análise no \mathbb{R}^n e dos lemas a seguir.

Seja U^* o conjunto dos minimizadores da função convexa f e suponhamos que a seqüência de números positivos $\{\lambda_k\}$ é tal que $\sum_{k=0}^{\infty} \frac{1}{\lambda_k} = +\infty$. Provaremos nesta seção que a seqüência $\{x_k\}$ dada pela iteração (IV.2.1) converge, se o conjunto U^* é não vazio, e diverge se U^* é vazio.

A Definição IV.2.2 e o próximo lema, são resultados gerais sobre a seqüência, que independem das características da função.

Definição IV.2.2. Uma seqüência $\{x_k\} \subset \mathbb{R}^n$ é dita *Fejér convergente* ao conjunto $U \neq \emptyset$, $U \subset \mathbb{R}^n$, se

$$\|u - x_{k+1}\| \leq \|u - x_k\|, \quad (\text{IV.2.3})$$

para todo $k \geq 0$ e todo $u \in U$.

Lema IV.2.3. *Se $\{x_k\}$ é Fejér convergente ao conjunto $\emptyset \neq U \subset \mathbb{R}^n$, então $\{x_k\}$ é uma seqüência limitada. Se, além disso, um ponto de acumulação \bar{x} da seqüência $\{x_k\}$ pertence a U , então $\bar{x} = \lim_{k \rightarrow +\infty} x_k$.*

Demonstração. Dado $u \in U$, a desigualdade (IV.2.3) implica que $\|u - x_k\| \leq \|u - x_0\|$, para todo k . Deste modo a seqüência $\{x_k\}$ é limitada. Agora sejam $\bar{x} \in U$ um ponto de acumulação de $\{x_k\}$ e $\{x_{k_j}\}$ uma subseqüência de $\{x_k\}$ tal que $\lim_{j \rightarrow +\infty} x_{k_j} = \bar{x}$. Como $\bar{x} \in U$, segue de (IV.2.3) que a seqüência de números reais positivos $\{\|x_k - \bar{x}\|\}$ é monótona não-crescente e possui uma subseqüência, a saber $\{\|x_{k_j} - \bar{x}\|\}$, convergindo para zero. Então a seqüência converge para zero, isto é, $0 = \lim_{k \rightarrow +\infty} \|x_k - \bar{x}\|$, o que significa $\lim_{k \rightarrow +\infty} x_k = \bar{x}$. \square

A hipótese feita sobre a seqüência $\{\lambda_k\}$ é motivada pelo lema a seguir.

Lema IV.2.4. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa. Se a seqüência $\{x_k\}$ é gerada pelo algoritmo (IV.2.1), então vale a desigualdade*

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

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

Demonstração. Seja $x \in \mathbb{R}^n$. Considere as igualdades

$$\begin{aligned} \|x - x_k\|^2 &= \|x - x_{k+1} + x_{k+1} - x_k\|^2 \\ &= \langle (x - x_{k+1}) + (x_{k+1} - x_k), (x - x_{k+1}) + (x_{k+1} - x_k) \rangle \\ &= \|x - x_{k+1}\|^2 - 2\langle x_k - x_{k+1}, x - x_{k+1} \rangle + \|x_{k+1} - x_k\|^2. \end{aligned}$$

Isto implica que

$$\|x - x_{k+1}\|^2 = \|x - x_k\|^2 - \|x_{k+1} - x_k\|^2 + 2\langle x_k - x_{k+1}, x - x_{k+1} \rangle. \quad (\text{IV.2.4})$$

Pelo Teorema IV.2.1,

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

Da definição de $\partial f(x_{k+1})$ temos

$$\begin{aligned} f(x) &\geq f(x_{k+1}) + \langle 2\lambda_k(x_k - x_{k+1}), x - x_{k+1} \rangle \\ &= f(x_{k+1}) + 2\lambda_k \langle x_k - x_{k+1}, x - x_{k+1} \rangle, \end{aligned}$$

e isto implica que

$$\frac{1}{\lambda_k}(f(x) - f(x_{k+1})) \geq 2\langle x_k - x_{k+1}, x - x_{k+1} \rangle. \quad (\text{IV.2.5})$$

Substituindo (IV.2.5) em (IV.2.4) temos

$$\|x - x_{k+1}\|^2 \leq \|x - x_k\|^2 - \|x_{k+1} - x_k\|^2 + \frac{1}{\lambda_k}(f(x) - f(x_{k+1})), \quad (\text{IV.2.6})$$

que é o resultado desejado. \square

Corolário IV.2.5. *Se $\{x_k\}$ é a seqüência gerada por (IV.2.1), então vale a desigualdade*

$$\|x - x_{k+1}\|^2 \leq \|x - x_k\|^2 + \frac{1}{\lambda_k}(f(x) - f(x_{k+1})), \quad (\text{IV.2.7})$$

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

Demonstração. Segue do Lema IV.2.4. \square

Demonstraremos a seguir o principal resultado deste capítulo: a convergência do algoritmo de ponto proximal.

Teorema IV.2.6. *Sejam $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa e $\{x_k\}$ a seqüência gerada por (IV.2.1). Se a seqüência $\{\lambda_k\}$ 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 $\lim_{k \rightarrow +\infty} x_k = x_*$, com $x_* \in U^*$.*

Demonstração. Seja U^* o conjunto dos minimizadores da função convexa f . Se $x_k \in U^*$, para algum $k > 0$, pela iteração do algoritmo obtemos $x_k = x_{k+1} = x_{k+2} = \dots$ e daí $f(x_k) = f_*$ e não há mais nada a fazer. Agora suponhamos que $x_k \notin U^*$, para todo k . Substituindo x por x_k em (IV.2.6) concluímos que a seqüência $\{f(x_k)\}$ é estritamente decrescente. Devemos provar que $\lim_{k \rightarrow +\infty} f(x_k) = f_*$. Suponhamos então, por absurdo, que $\lim_{k \rightarrow +\infty} f(x_k) > f_*$. Então existe $x \in \mathbb{R}^n$ e $\delta > 0$ tal que

$$f(x) < f(x_k) - \delta, \quad (\text{IV.2.8})$$

para todo $k > 0$. Substituindo a desigualdade (??) na inequação (??), temos

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

para todo k . Mas isto implica que

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

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

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

para todo j , o que contraria $\sum_{k=0}^{\infty} \frac{1}{\lambda_k} = +\infty$. Logo $\lim_{k \rightarrow +\infty} f(x_k) = f_*$. Se, além disso, $U^* \neq \emptyset$, tome $\bar{x} \in U^*$. Deste modo $f(\bar{x}) \leq f(x_k)$, para todo k . Substituindo x por \bar{x} em (IV.2.7) obtemos $\|\bar{x} - x_{k+1}\|^2 \leq \|\bar{x} - x_k\|^2$, para todo k , e assim a seqüência $\{x_k\}$ é Fejér convergente a U^* . Logo, pelo Lema IV.2.3, $\{x_k\}$ é limitada. Seja $\{x_{k_j}\}$ uma subsequência convergente de $\{x_k\}$, digamos $\lim_{j \rightarrow +\infty} x_{k_j} = x_*$. Da primeira parte $\lim_{j \rightarrow +\infty} f(x_{k_j}) = f_*$ e, sendo f contínua, $f(x_*) = f_*$, o que implica $x_* \in U^*$. Portanto, novamente do Lema IV.2.3, concluímos que a seqüência $\{x_k\}$ converge a x_* , isto é, $\lim_{k \rightarrow +\infty} x_k = x_*$. \square

IV.3 Observações finais

Vimos neste capítulo que a seqüência gerada pela iteração do método de ponto proximal é unicamente determinada. Na análise de convergência do método mostramos que o limite dos valores funcionais de $f(x_k)$ tende ao ínfimo da função f quando $k \rightarrow +\infty$. Caso este ínfimo seja $-\infty$, ou não seja atingido, a seqüência $\{x_k\}$ diverge, senão a seqüência é Fejér convergente ao conjunto não vazio U^* dos minimizadores da função convexa f .

CAPÍTULO V

Operadores Monótonos Maximais

V.1 Introdução

Encontrar singularidades de operadores é um problema clássico em equações diferenciais. Um importante resultado devido à Rockafellar [11] que estudaremos no Capítulo VI, é utilizar o algoritmo de ponto proximal para determinar zeros de um operador monótono maximal arbitrário. No Capítulo III verificamos que um ponto $x_* \in \mathbb{R}^n$ é um minimizador de uma função convexa $f: \mathbb{R}^n \rightarrow \mathbb{R}$ se, e somente se, $0 \in \partial f(x_*)$. Sendo ∂f um operador monótono maximal, como será visto a seguir, o problema de descobrir suas singularidades generaliza, em um certo sentido, o problema de minimizar funções convexas.

Neste capítulo introduziremos o conceito de operadores monótonos em \mathbb{R}^n , operadores monótonos ponto-conjunto e operadores monótonos maximais (veja Iusem [4] e Ortega-Rheinboldt [9]). Encerraremos o capítulo provando a maximalidade do subdiferencial de uma função convexa. No próximo capítulo estudaremos o algoritmo de ponto proximal para operadores monótonos maximais arbitrários.

V.2 Operadores Monótonos contínuos

Nesta seção, veremos que o conceito de convexidade está relacionado com o conceito de monotonicidade, isto é, uma função diferenciável é convexa se, e somente se, o seu gradiente é monótono. Este fato nos fornece uma classe de exemplos de operadores monótonos, a saber, aqueles que são gradientes de funções convexas. Naturalmente surge a pergunta: todo operador monótono é gradiente de uma função convexa? Daremos um exemplo de operadores monótonos que não são gradientes de funções convexas utilizando um “critério” conhecido para determinar convexidade de uma função: verificando se a *hessiana* é uma matriz simétrica, para todo $x \in \mathbb{R}^n$.

Definição V.2.1. Dizemos que o operador $T: \mathbb{R}^n \rightarrow \mathbb{R}^n$ é *monótono* se

$$\langle T(x) - T(y), x - y \rangle \geq 0, \quad (\text{V.2.1})$$

para todos x e $y \in \mathbb{R}^n$. Dizemos ainda que T é *estritamente monótono* se a desigualdade (V.2.1) é estrita.

Proposição V.2.2. *Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável. f é convexa se, e somente se, $\nabla f: \mathbb{R}^n \rightarrow \mathbb{R}^n$ é monótono.*

Demonstração. Suponha f convexa. Dados x e $y \in \mathbb{R}^n$ vale, pelo Teorema III.3.21,

$$f(x) \geq f(y) + \langle \nabla f(y), x - y \rangle \quad \text{e} \quad f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle,$$

que é equivalente, respectivamente, a

$$\langle -\nabla f(y), x - y \rangle \geq f(y) - f(x) \quad \text{e} \quad \langle \nabla f(x), x - y \rangle \geq f(x) - f(y).$$

Somando-se os lados correspondentes das desigualdades acima obtemos

$$\langle \nabla f(x) - \nabla f(y), x - y \rangle \geq 0.$$

Portanto, ∇f é monótono. Reciprocamente, suponha ∇f monótono. Pela inequação (V.2.1), vale: $\langle \nabla f(x), x - y \rangle \geq \langle \nabla f(y), x - y \rangle$. Recorrendo ao *Teorema do Valor Médio*:

$$f(y) - f(x) = \langle \nabla f(\xi), y - x \rangle,$$

para todo $x, y \in \mathbb{R}^n$ e algum $\xi \in (x, y)$. Assim, existe $\alpha \in (0, 1)$, tal que:

$$\begin{aligned} f(y) - f(x) &= \langle \nabla f(\xi), \frac{\xi - x}{\alpha} \rangle = \frac{1}{\alpha} \langle \nabla f(\xi), \xi - x \rangle \\ &\geq \frac{1}{\alpha} \langle \nabla f(x), \xi - x \rangle = \langle \nabla f(x), y - x \rangle. \end{aligned}$$

Novamente, pelo Teorema III.3.21, f é convexa se, e somente se, $f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle$, para todo $x, y \in \mathbb{R}^n$. Assim, concluimos o que desejávamos. \square

Exemplo V.2.3. Seja $A \in M_{n \times n}$ uma matriz anti-simétrica e considere o operador

$$T: \mathbb{R}^n \rightarrow \mathbb{R}^n$$

$$x \mapsto T(x) = Ax.$$

Dados $x, y \in \mathbb{R}^n$,

$$\begin{aligned} \langle T(x) - T(y), x - y \rangle &= \langle A(x - y), x - y \rangle = \langle x - y, A^t(x - y) \rangle \\ &= \langle x - y, -A(x - y) \rangle = -\langle A(x - y), x - y \rangle \\ &= -\langle T(x) - T(y), x - y \rangle, \end{aligned}$$

o que implica $\langle T(x) - T(y), x - y \rangle = 0$. Portanto, T é monótono. Observemos que $T(x) = Ax$ não pode ser gradiente de nenhuma função, pois senão deveria existir uma função f , duas vezes diferenciável, tal que $\nabla f(x) = Ax = T(x)$ e $\nabla^2 f(x) = A$, o que é um absurdo, pois a *hessiana* $\nabla^2 f(x)$ é simétrica, ao passo que A é anti-simétrica.

V.3 Operadores monótonos ponto-conjunto

Neste momento, consideremos um operador T que associa, para cada $x \in \mathbb{R}^n$, um subconjunto de \mathbb{R}^n . Chamaremos este operador com contradomínio no conjunto das partes de \mathbb{R}^n , $\mathcal{P}(\mathbb{R}^n)$, de operador ponto-conjunto. Definiremos nesta seção os operadores monótono maximais, que são multifunções estudadas extensivamente por causa de seu importante papel em análise convexa e em equações diferenciais. Mostraremos no final da seção que o subdiferencial de uma função convexa é um operador monótono maximal.

Seja $f: \mathbb{R}^n \rightarrow \mathbb{R}$ convexa, não necessariamente diferenciável. Dados $x, y \in \mathbb{R}^n$, tomemos $\xi, \eta \in \mathbb{R}^n$, tais que $\xi \in \partial f(x)$ e $\eta \in \partial f(y)$ e

$$\begin{aligned} f(x) &\geq f(y) + \langle \eta, x - y \rangle \Rightarrow \langle -\eta, x - y \rangle \geq f(y) - f(x), \\ f(y) &\geq f(x) + \langle \xi, y - x \rangle \Rightarrow \langle \xi, x - y \rangle \geq f(x) - f(y). \end{aligned}$$

Somando termo a termo as desigualdades à direita obtemos

$$\langle \xi - \eta, x - y \rangle \geq 0. \quad (\text{V.3.1})$$

Como $\partial f: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$ associa para cada x não exatamente um vetor, mas um subconjunto de \mathbb{R}^n , estenderemos a noção de operador monótono ponto-ponto para operador monótono ponto-conjunto.

Definição V.3.1. $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$ é monótono se

$$0 \leq \langle x - y, u - v \rangle,$$

para todo $x \in \mathbb{R}^n$, $y \in \mathbb{R}^n$, $u \in T(x)$ e $v \in T(y)$.

Observação V.3.2. Segue de (V.3.1) que, se f é convexa, então ∂f é monótono.

Assim para operadores não gradientes, monotonicidade pode ser considerada como uma generalização natural de convexidade.

Definição V.3.3. $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$ é *monótono maximal* se,

(i) T é monótono;

(ii) Para todo T' monótono tal que $T(x) \subset T'(x)$ para todo x , vale que $T = T'$.

Geometricamente, a definição acima diz que, se um operador T é monótono, e se o seu gráfico $G(T) = \{(z, w) \in \mathbb{R}^n \times \mathbb{R}^n : w \in T(z)\}$ não está contido propriamente no gráfico de nenhum outro operador monótono $T': \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$, então T é monótono maximal.

No próximo capítulo exibiremos o algoritmo de ponto proximal para operadores monótonos maximais arbitrários. Basicamente, este algoritmo resolve o problema de encontrar singularidades deste tipo de operador. Sendo ∂f monótono para toda função convexa f , desejamos verificar a sua maximalidade, pois desta forma estaremos generalizando o problema de minimizar funções convexas. No intuito de demonstrar a maximalidade do operador ∂f provaremos o Lema V.3.4.

Sejam $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa e $x_0 \in \mathbb{R}^n$. Defina a função

$$F: \mathbb{R}^n \rightarrow \mathbb{R}$$

$$x \mapsto F(x) = f(x) + \frac{1}{2}\|x - x_0\|^2. \quad (\text{V.3.2})$$

Já mostramos, no Capítulo IV, que F possui um único minimizador. Introduzindo uma notação mais adequada, definimos:

$$\text{prox}_f(x_0) := \underset{x \in \mathbb{R}^n}{\text{argmin}} \left\{ f(x) + \frac{1}{2}\|x - x_0\|^2 \right\}.$$

Lema V.3.4. *Sejam $f: \mathbb{R}^n \rightarrow \mathbb{R}$ uma função convexa e $x, y, z \in \mathbb{R}^n$. As seguintes condições são equivalentes:*

- (i) $z = x + y$ e $f(x) + f^*(y) = \langle x, y \rangle$;
- (ii) $x = \text{prox}_f(z)$ e $y = \text{prox}_{f^*}(z)$.

Demonstração. Faremos algumas considerações preliminares antes de provarmos as equivalências. Defina $h: \mathbb{R}^n \rightarrow \mathbb{R}$ por:

$$h(u) = \frac{1}{2} \|u - z\|^2.$$

Logo, $F = f + h$. Fazendo $x = \text{prox}_f(z)$, temos que x é um minimizador da função F se, e somente se, $0 \in \partial F(x)$, que é equivalente a $0 \in (\partial f(x) + \partial h(x))$. Mas $\nabla h(u) = u - z$, e isto implica

$$x = \text{prox}_f(z) \Leftrightarrow 0 \in (\partial f(x) + \{x - z\}), \quad (\text{V.3.3})$$

ou seja, existe $y \in \partial f(x)$ tal que $z = x + y$. Analogamente, podemos mostrar que

$$y = \text{prox}_{f^*}(z). \quad (\text{V.3.4})$$

Isto é, existe $x \in \partial f^*(y)$ tal que $z = x + y$. O Teorema III.3.31 e a Proposição III.3.35 implicam

$$y \in \partial f(x) \Leftrightarrow f(x) + f^*(y) = \langle x, y \rangle \Leftrightarrow x \in \partial f^*(y). \quad (\text{V.3.5})$$

(i) \Rightarrow (ii) Por hipótese $z = x + y$ e $f(x) + f^*(y) = \langle x, y \rangle$. Então, da equação (V.3.5) obtemos

$$y \in \partial f(x) \text{ e } x \in \partial f^*(y).$$

Combinando estes resultados com (i), (V.3.3) e (V.3.4) obtemos

$$x = \text{prox}_f(z) \text{ e } y = \text{prox}_{f^*}(z).$$

(i) \Leftarrow (ii) Seja $x = \text{prox}_f(z)$. Da equação (V.3.3) obtemos a existência de um $y_0 \in \partial f(x)$ tal que $z = x + y_0$. Observemos que a equação (V.3.5) implica

$$x \in \partial f^*(y_0) \text{ e } f(x) + f^*(y_0) = \langle x, y_0 \rangle.$$

Combinando esses resultados com (V.3.4) obtemos $y_0 = \text{prox}_{f^*}(z) = y$. Daí segue que

$$z = x + y \text{ e } f(x) + f^*(y) = \langle x, y \rangle. \quad \square$$

Teorema V.3.5. *Se $f: \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa então $\partial f: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$ é monótono maximal.*

Demonstração. Pela Observação V.3.2, ∂f é monótono. Provemos que ∂f é maximal, para todo $x \in \mathbb{R}^n$. Suponha que exista um operador $T(x)$ tal que $\partial f(x) \subset T(x)$, para todo $x \in \mathbb{R}^n$. Mostremos que se $y \in T(x)$, então $y \in \partial f(x)$. Sejam $x_0, y_0 \in \mathbb{R}^n$, com $y_0 \in T(x_0)$. Se $y \in T(x)$, então

$$\langle x - x_0, y - y_0 \rangle \geq 0, \quad (\text{V.3.6})$$

para todo $x, y \in \mathbb{R}^n$ com $y \in \partial f(x)$, pois T é monótono. Tome $x_1 = \text{prox}_f(x_0 + y_0)$ e $y_1 = \text{prox}_{f^*}(x_0 + y_0)$. O Lema V.3.4 e o Teorema III.3.31 implicam

$$x_0 + y_0 = x_1 + y_1 \text{ e } y_1 \in \partial f(x_1) \subset T(x_1). \quad (\text{V.3.7})$$

Fazendo $x = x_1$ e $y = y_1$ em (V.3.6) obtemos, de (V.3.7), que

$$0 \leq \langle y_1 - y_0, x_1 - x_0 \rangle = \langle x_0 - x_1, x_1 - x_0 \rangle = -\|x_0 - x_1\|^2.$$

Conseqüentemente $x_0 = x_1$ e $y_0 = y_1 \in \partial f(x_1) = \partial f(x_0)$. Assim, concluímos que ∂f é monótono maximal. \square

CAPÍTULO VI

O algoritmo para operadores monótonos maximais

VI.1 Introdução

O algoritmo de ponto proximal é fundamental para resolver o problema de encontrar $x \in \mathbb{R}^n$ tal que $0 \in T(x)$, onde T é um operador monótono maximal. O algoritmo é baseado no fato (veja Minty [7]) de que para cada $z \in \mathbb{R}^n$ e $c > 0$, existe um único $u \in \mathbb{R}^n$ tal que $z - u \in cT(u)$, ou, em outras palavras,

$$z \in (I + cT)(u). \tag{VI.1.1}$$

Neste capítulo generalizaremos o algoritmo de ponto proximal apresentado no Capítulo IV. Mostraremos que a seqüência $\{x_k\} \subset \mathbb{R}^n$ gerada pela iteração obtida para o caso de operador monótono maximal está bem definida e que, se existir $\bar{x} \in \mathbb{R}^n$ tal que $0 \in T(\bar{x})$, então a seqüência $\{x_k\}$ convergirá para uma singularidade do operador T .

VI.2 O algoritmo

Nesta seção obteremos a iteração que define o método de ponto proximal para operadores monótonos maximais. Para tanto definiremos a inversa de um operador ponto-conjunto.

Definição VI.2.1. Seja $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$. Definimos a *inversa* de T como

$$\begin{aligned} T^{-1}: \mathbb{R}^n &\rightarrow \mathcal{P}(\mathbb{R}^n) \\ x &\mapsto T^{-1}(x), \end{aligned}$$

onde $y \in T^{-1}(x)$ se, e somente se, $x \in T(y)$.

No Capítulo IV vimos que, dada uma função convexa f , o algoritmo de ponto proximal para minimização em \mathbb{R}^n gera, para um ponto inicial $x_0 \in \mathbb{R}^n$, uma seqüência $\{x_k\}$ pela iteração $x_{k+1} := \arg \min_{x \in \mathbb{R}^n} \{f(x) + \lambda_k \|x_k - x\|^2\}$, o que implicava

$$0 \in \partial f(x_{k+1}) + \{2\lambda_k(x_{k+1} - x_k)\} \Leftrightarrow 2\lambda_k(x_k - x_{k+1}) \in \partial f(x_{k+1}).$$

Disto e de (VI.1.1) temos que

$$x_k \in (I + \frac{1}{2\lambda_k} \partial f)(x_{k+1}).$$

A partir desta relação de pertinência definimos o algoritmo de ponto proximal para encontrar os zeros de um operador monótono maximal arbitrário $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$ da seguinte forma:

Para um ponto inicial $x_0 \in \mathbb{R}^n$ e $\{\lambda_k\}$ uma seqüência de números reais tais que $\lambda_k > 0$, para todo k , a iteração de ponto proximal

$$x_{k+1} \in (I + \frac{1}{2\lambda_k} T)^{-1}(x_k) \tag{VI.2.1}$$

gera a seqüência $\{x_k\} \subset \mathbb{R}^n$, que define o algoritmo.

VI.2.1 Boa definição

A boa definição do algoritmo está fundamentada no Teorema de Minty, enunciado como Teorema VI.2.4, cuja demonstração será omitida e pode ser encontrada em Minty [7]. As definições a seguir serão introduzidas por fazerem parte das hipóteses do Teorema de Minty.

Definição VI.2.2. Seja $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$.

- (i) Dizemos que T é *sobrejetivo* se, para todo $y \in \mathbb{R}^n$, existe $x \in \mathbb{R}^n$ tal que $y \in T(x)$.
- (ii) Dizemos que T é *injetivo* se, para todos $x, y \in \mathbb{R}^n$, $x \neq y$, implica $T(x) \cap T(y) = \emptyset$.

Definição VI.2.3. Dizemos que $P: \mathbb{R}^n \rightarrow \mathbb{R}^n$ é firmemente não-expansivo se

$$\|P(x) - P(y)\|^2 \leq \|x - y\|^2 - \|(x - y) - (P(x) - P(y))\|^2,$$

para todos x e y em \mathbb{R}^n .

Teorema VI.2.4. (Teorema de Minty) Se $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$ é um operador monótono maximal e $\mu > 0$, então $I + \mu T$ é injetivo e sobrejetivo e $(I + \mu T)^{-1}$ é firmemente não expansivo.

Em particular, o Teorema de Minty é um teorema de existência: se T é um operador monótono maximal, então a sentença $y \in T(x)$ tem solução para todo x .

Proposição VI.2.5. A seqüência $\{x_k\}$ gerada pelo algoritmo (VI.2.1) está bem definida.

Demonstração. Do Teorema de Minty, T é sobrejetivo e, para todo k , existe $x_{k+1} \in \mathbb{R}^n$ tal que

$$x_{k+1} \in \left(I + \frac{1}{2\lambda_k} T\right)^{-1}(x_k). \quad \square$$

VI.2.2 Convergência

A convergência do algoritmo de ponto proximal para operadores monótonos maximais arbitrários, tal como no artigo de Rockafellar [11], deve-se à suposição inicial da existência de um $\bar{x} \in \mathbb{R}^n$ tal que $0 \in T(\bar{x})$. Na demonstração do teorema da convergência usamos o resultado do Lema VI.2.6 que supõe existirem seqüências y_k e z_k tais que $y_k \in T(z_k)$, onde T é monótono maximal.

Lema VI.2.6. *Se $\lim_{k \rightarrow +\infty} y_k = \bar{y}$, $\lim_{k \rightarrow +\infty} z_k = \bar{z}$, T é monótono maximal e $y_k \in T(z_k)$, então $\bar{y} \in T(\bar{z})$.*

Demonstração. Defina T' como

$$T'(z) = \begin{cases} T(z), & \text{se } z \neq \bar{z} \\ T(\bar{z}) \cup \{\bar{y}\}, & \text{se } z = \bar{z} \end{cases}.$$

Queremos mostrar que T' é monótono. Para isso devemos checar

$$\langle y - y', z - z' \rangle \geq 0, \quad (\text{VI.2.2})$$

para todo z e $z' \in \mathbb{R}^n$ e para todo $y \in T'(z)$ e $y' \in T'(z')$. Como T é monótono basta verificar (VI.2.2) apenas para $y' = \bar{y}$ e $z' = \bar{z}$. Pela monotonicidade de T , para todo k :

$$\langle y - y_k, z - z_k \rangle \geq 0,$$

para todo z e para todo $y \in T(z)$. Usando o fato que $y_k \rightarrow \bar{y}$ e $z_k \rightarrow \bar{z}$ implicam $\langle y - \bar{y}, z - \bar{z} \rangle \geq 0$, temos que T' é monótono. Como $T(x) \subset T'(x)$ para todo x e T é monótono maximal, concluímos que $T = T'$ e em particular $T(\bar{z}) = T'(\bar{z}) = T(\bar{z}) \cup \{\bar{y}\}$, isto é, $\bar{y} \in T(\bar{z})$. \square

Teorema VI.2.7. *Se $T: \mathbb{R}^n \rightarrow \mathcal{P}(\mathbb{R}^n)$ é monótono maximal e existe \bar{x} tal que $0 \in T(\bar{x})$, então a seqüência $\{x_k\}$ definida em (VI.2.1), com $0 < \lambda_k < \tilde{\lambda}$, converge para um vetor x_* tal que $0 \in T(x_*)$.*

Demonstração. Tome $\bar{x} \in \mathbb{R}^n$ tal que $0 \in T(\bar{x})$. Temos

$$\begin{aligned} \|x_k - \bar{x}\|^2 &= \langle (x_k - x_{k+1}) + (x_{k+1} - \bar{x}), (x_k - x_{k+1}) + (x_{k+1} - \bar{x}) \rangle \\ &= \|x_k - x_{k+1}\|^2 + 2\langle x_k - x_{k+1}, x_{k+1} - \bar{x} \rangle + \|x_{k+1} - \bar{x}\|^2, \end{aligned}$$

o que implica que

$$\|x_{k+1} - \bar{x}\|^2 = \|x_k - \bar{x}\|^2 - \|x_k - x_{k+1}\|^2 - \frac{1}{\lambda_k} \langle 2\lambda_k(x_k - x_{k+1}), x_{k+1} - \bar{x} \rangle. \quad (\text{VI.2.3})$$

Por hipótese $0 \in T(\bar{x})$ e, pelo Teorema IV.2.1, $2\lambda_k(x_k - x_{k+1}) \in T(x_{k+1})$. Sendo T monótono temos que

$$\langle 2\lambda_k(x_k - x_{k+1}) - 0, x_{k+1} - \bar{x} \rangle \geq 0,$$

donde obtemos

$$0 < \|x_{k+1} - \bar{x}\|^2 \leq \|x_k - \bar{x}\|^2 - \|x_k - x_{k+1}\|^2, \quad (\text{VI.2.4})$$

para todo $k > 0$. Desta desigualdade resulta que a seqüência $\{\|x_k - \bar{x}\|\}$ é monótona decrescente e limitada, portanto convergente. Também vale

$$\|x_k - x_{k+1}\|^2 \leq \|x_k - \bar{x}\|^2 - \|x_{k+1} - \bar{x}\|^2,$$

para todo k . Passando ao limite quando $k \rightarrow +\infty$, obtemos $\lim_{k \rightarrow +\infty} (x_k - x_{k+1}) = 0$.

Da equação (VI.2.4) também resulta que a seqüência $\{x_k\}$ é Fejér convergente ao conjunto $O^* = \{z \in \mathbb{R}^n : 0 \in T(z)\}$. Assim, pelo Lema IV.2.3, $\{x_k\}$ é limitada. Seja x_* um ponto de acumulação de $\{x_k\}$ e $\{x_{j_k}\}$ uma subseqüência de $\{x_k\}$ tal que $\lim_{k \rightarrow +\infty} x_{j_k} = x_*$, e vale que $\lim_{k \rightarrow +\infty} (x_{j_k} - x_{j_k+1}) = 0$. Pela iteração do algoritmo definido em (VI.2.1), temos que

$$2\lambda_{j_k}(x_{j_k} - x_{j_k+1}) \in T(x_{j_k+1}).$$

Como, por hipótese, $0 < \lambda_k < \tilde{\lambda}$, segue que $\lim_{k \rightarrow +\infty} (2\lambda_{j_k}(x_{j_k} - x_{j_{k+1}})) = 0$. Sendo T maximal, do Lema VI.2.6, com $y_k = 2\lambda_{j_k}(x_{j_k} - x_{j_{k+1}})$, $\bar{y} = 0$, $z_k = x_{j_{k+1}}$ e $\bar{z} = x_*$ vem que $0 \in T(x_*)$, o que significa dizer que $x_* \in O^*$. Pela Fejér convergência da seqüência $\{x_k\}$ ao conjunto O^* segue, do Lema IV.2.3, que

$$\lim_{k \rightarrow +\infty} x_k = x_* . \quad \square$$

VI.2.3 Observações finais

Para a convergência do algoritmo de ponto proximal no caso de operadores monótonos maximais, foi essencial a suposição da existência de um $\bar{x} \in \mathbb{R}^n$ tal que $0 \in T(\bar{x})$. Apesar da determinação das singularidades de um operador monótono maximal generalizar o problema de minimização de funções convexas, pois o operador ∂f é monótono maximal, na análise de convergência feita neste capítulo foi essencial a hipótese de que o conjunto dos minimizadores U^* da função objetivo fosse não vazio, o que não ocorreu na análise de convergência feita no Capítulo IV.

Esta dissertação é um estudo introdutório do algoritmo de ponto proximal para otimização convexa. Mas por tratar-se de um tema muito atual ele será de grande valor para estudar outras variantes do algoritmo, como é feito, por exemplo, em [4].

Bibliografia

- [1] R. Correa and C. Lemaréchal, Convergence of some algorithms for convex minimization, *Mathematical Programming* **62** (1993), 267–275.
- [2] O. Güler, On the convergence of the proximal point algorithm for convex minimization, *SIAM J. Cont. and Opt.*, **29**, (1991), 403–419.
- [3] J.-B. Hiriart-Urruty and C. Lemaréchal, *Convex analysis and minimization algorithms I and II*, Springer-Verlag (1993).
- [4] A. N. Iusem, Proximal point methods in optimization, 20^o Colóquio Brasileiro de Matemática, IMPA, (1995).
- [5] E. L. Lima, *Curso de análise, Volume 2*, Instituto de Matemática Pura e Aplicada, Rio de Janeiro, 1981.
- [6] B. Martinet, Régularisation, d'inéquations variationelles par approximations successives, *Revue Française d'Informatique et de Recherche Operationelle*, (1970), 154–159.
- [7] G. J. Minty, Monotone (nonlinear) operators in Hilbert space, *Duke Math. J.*, **29** (1962), 341–346.

- [8] J. J. Moreau, Proximité et dualité dans un espace Hilbertien, Bull. Soc. Math., France, **93** (1965), 273–299.
- [9] J. M. Ortega, W.C. Rheinboldt. Iterative solution of nonlinear equations in several variables, Academic Press, Inc, New York (1970).
- [10] R. T. Rockafellar, Convex analysis, Princeton University Press, Princeton, 1970.
- [11] R. T. Rockafellar. Monotone operators and the proximal point algorithm. SIAM J. cont. optim. **14** (1976), 877–898.
- [12] Jan van Tiel. Convex analysis: an introductory text, Royal Netherlands Meteorological Institute, 1984.