
Um Algoritmo de Ponto Proximal Inexato para Programação Multiobjetivo

Rogério Azevedo Rocha¹

Curso de Ciência da Computação, UFT, Palmas, TO

Ronaldo Malheiros Gregório²

Departamento de Tecnologia e Linguagens, UFRRJ, Rio de Janeiro, RJ

Resumo. Consideramos o problema de otimização multiobjetivo de encontrar pontos Pareto fraco para aplicações convexas $F : \mathbb{R}^n \rightarrow \mathbb{R}^m$. Para este problema, propomos uma versão inexata do algoritmo de ponto proximal vetorial de Rocha et al.. Mostramos que qualquer sequência gerada pela versão inexata é limitada e que seus pontos de acumulação são soluções Pareto fraco para o problema.

Palavras-chave. Algoritmo de Ponto Proximal, Otimização Multiobjetivo, Solução Pareto Fraco, Quase-distância

1 Introdução

O clássico algoritmo de ponto proximal (APP) para otimizar uma função convexa de valor escalar $f : \mathbb{R}^n \rightarrow \mathbb{R}$ foi originalmente introduzido por Martinet [5] e desenvolvido e estudado por Rockafellar [11]. Este APP gera uma sequência $\{x^k\}$ via o seguinte procedimento iterativo: Dado um ponto inicial $x^0 \in \mathbb{R}^n$,

$$x^{k+1} \in \operatorname{argmin}\{f(x) + \lambda_k \|x - x^k\|^2 \mid x \in \mathbb{R}^n\}, \quad (1)$$

onde λ_k é uma sequência de números reais positivos e $\|\cdot\|$ é a norma usual.

Em recentes décadas a análise de convergência deste APP tem sido amplamente estudada e conseqüentemente surgiram, na literatura, inúmeras generalizações/variações deste APP para diversas classes de problemas, dentre as quais, destacamos a otimização multiobjetivo/vetorial. Dentre os trabalhos existentes na literatura, que envolvem o APP aplicado a problemas multiobjetivo, citamos: Bonnel et al. [2] e Rocha et al. [9, 10].

Rocha et al [10] desenvolveram um APP aplicado à problemas de otimização multiobjetivo irrestrito e convexo. Uma de suas principais contribuições foi a introdução da aplicação quase-distância nos subproblemas regularizados do APP, que possui importantes aplicações em teoria da computação [3] e economia [8], entre outras. Sob certas hipóteses

¹azevedo@uft.edu.br

²rgregor@ufrj.br

razoáveis, mostraram a convergência do APP para soluções Pareto fraco e, devido a importância das soluções Pareto para as aplicações, exibiram uma classe de seqüências que são geradas pelo algoritmo e que convergem para solução Pareto (em vez de Pareto fraco).

Neste trabalho, propomos uma versão inexata do algoritmo proximal de Rocha et al. [10]. Segundo Rockafellar [11], a importância das versões inexatas é que, para que um APP seja prático é importante que ele funcione com soluções aproximadas dos subproblemas.

Na seção 2 apresentamos conceitos e resultados relacionados a aplicação quase-distância, teoria do subdiferencial e programação multiobjetivo. Na seção 3, apresentamos nosso algoritmo proximal onde asseguramos a existência das iteradas e a convergência para soluções Pareto fraco.

2 Preliminares

Nesta seção, apresentaremos algumas Definições e Proposições básicas para a prova do nosso principal resultado.

Definição 2.1. *Sejam $x, y \in \mathbb{R}^m$ vetores. (a) $x \leq y \iff x_i \leq y_i, \forall i = 1, \dots, m$; (b) $x \ll y \iff x_i < y_i, \forall i = 1, \dots, m$; (c) $x < y \iff x_i \leq y_i, \forall i = 1, \dots, m$, com a desigualdade estrita assegurada para pelo menos um índice.*

Considere uma aplicação convexa $G : \mathbb{R}^n \rightarrow \mathbb{R}^m$ e o seguinte problema de otimização multiobjetivo (POM)

$$\text{MINIMIZE } \{G(x) \mid x \in \mathbb{R}^n\}. \tag{2}$$

Definição 2.2. *(a) $a \in \mathbb{R}^n$ é uma solução Pareto para o problema (2) se não existe $x \in \mathbb{R}^n$ satisfazendo $G(x) < G(a)$; (b) $a \in \mathbb{R}^n$ é uma solução Pareto fraco para o problema (2) se não existe $x \in \mathbb{R}^n$ satisfazendo $G(x) \ll G(a)$.*

Denotaremos por $\text{argmin}\{G(x) \mid x \in \mathbb{R}^n\}$ e $\text{argmin}_w\{G(x) \mid x \in \mathbb{R}^n\}$ o conjunto solução Pareto e o conjunto solução Pareto fraco para o problema (2), respectivamente. É fácil conferir que: $\text{argmin}\{G(x) \mid x \in \mathbb{R}^n\} \subset \text{argmin}_w\{G(x) \mid x \in \mathbb{R}^n\}$.

Observação 2.1. *(Huang and Yang [4]) Dada uma aplicação $G : \mathbb{R}^n \rightarrow \mathbb{R}^m$, considere o POM*

$$\text{MINIMIZE}\{exp(G(x)) \mid x \in \mathbb{R}^n\}, \tag{3}$$

onde $exp(G(x)) = (exp(G_1(x)), \dots, exp(G_m(x)))$. Então, os conjuntos soluções Pareto fraco dos problemas (2) e (3) são os mesmos. Portanto, sem perda de generalidades, podemos assumir, que para todo $\bar{z} \in \mathbb{R}_+^m \setminus \{0\}$, $\langle G(x), \bar{z} \rangle > 0; \forall x \in \mathbb{R}^n$. Observe também que a convexidade do problema (2) implica na convexidade do problema (3).

Definição 2.3. *Seja $h : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ uma função própria e $x \in \mathbb{R}^n$.*

1. *O subdiferencial Fréchet de h em $x \in \mathbb{R}^n$, $\hat{\partial}h(x)$, é definido como segue:*

$$\hat{\partial}h(x) := \begin{cases} \left\{ x^* \in \mathbb{R}^n : \liminf_{y \neq x, y \rightarrow x} \frac{h(y) - h(x) - \langle x^*, y - x \rangle}{\|x - y\|} \geq 0 \right\}, & \text{se } x \in \text{dom}(h) \\ \emptyset, & \text{se } x \notin \text{dom}(h) \end{cases}$$

2. O subdiferencial-limite de h em $x \in \mathbb{R}^n$, $\partial h(x)$, é definido como segue:

$$\partial h(x) := \left\{ x^* \in \mathbb{R}^n : \exists x_n \rightarrow x, \quad h(x_n) \rightarrow h(x), \quad x_n^* \in \hat{\partial} h(x_n) \rightarrow x^* \right\}$$

Observação 2.2. **a)** Se $\bar{x} \in \text{dom}(h)$, então os conjuntos $\hat{\partial} h(\bar{x})$ e $\partial h(\bar{x})$ são fechados, com $\hat{\partial} h(\bar{x})$ convexo e $\hat{\partial} h(\bar{x}) \subset \partial h(\bar{x})$; e **b)** Seja $C \subseteq \mathbb{R}^n$. Se uma função própria $h : C \rightarrow \mathbb{R} \cup \{+\infty\}$ possui um mínimo local em $\bar{x} \in C$, então $0 \in \hat{\partial}(h + \delta_C)(\bar{x})$, $0 \in \partial(h + \delta_C)(\bar{x})$, onde $\delta_C : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ é a função indicadora de C .

Definição 2.4. Uma aplicação $q : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}_+$ é dita ser uma quase-distância se, para todos $x, y, z \in \mathbb{R}^n$,

$$(A1) \quad q(x, y) = q(y, x) = 0 \iff x = y \quad \text{e} \quad (A2) \quad q(x, z) \leq q(x, y) + q(y, z).$$

Observação 2.3. **a)** Se q é simétrica, isto é, se para todos $x, y \in \mathbb{R}^n$, $q(x, y) = q(y, x)$, então q é uma distância; **b)** Uma quase-distância não necessariamente é uma função convexa, nem continuamente diferenciável, e nem mesmo uma função coerciva em nenhum de seus argumentos (conf. [8, Observações 3 e 4]).

A seguinte Proposição providência uma classe de quase-distâncias que são localmente Lipschitz contínuas e coercivas em qualquer um de seus argumentos.

Proposição 2.1. Seja $q : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}_+$ uma quase-distância. Suponha que existem constantes positivas α e β tal que

$$\alpha \|x - y\| \leq q(x, y) \leq \beta \|x - y\|, \quad \forall x, y \in \mathbb{R}^n. \quad (4)$$

Então, para cada $\bar{z} \in \mathbb{R}^n$, $q(\bar{z}, \cdot)$ e $q(\cdot, \bar{z})$ são funções Lipschitz contínuas sobre \mathbb{R}^n , $q^2(\bar{z}, \cdot)$ e $q^2(\cdot, \bar{z})$ são funções localmente Lipschitz contínuas sobre \mathbb{R}^n e $q(\bar{z}, \cdot)$, $q(\cdot, \bar{z})$, $q^2(\bar{z}, \cdot)$ e $q^2(\cdot, \bar{z})$ são funções coercivas.

Demonstração. Conferir [8, Proposição 3.6 e 3.7 e Observação 5]. □

Observação 2.4. A classe de quase-distâncias não simétricas que satisfazem a propriedade (4) da Proposição anterior é não vazia. Conferir [8, Seção 3.1].

Proposição 2.2. Considere $\bar{u}, \bar{v} \in \mathbb{R}^n$ fixados e $q : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}_+$ uma quase-distância satisfazendo (4). Então existe $M > 0$, que não depende de \bar{u} e \bar{v} , tal que $\|x^*\| \leq M$ para todo $x^* \in \partial(q(\cdot, \bar{v}))(\bar{u})$.

Demonstração. Conferir [10, Proposição 2.3]. □

3 Algoritmo Proximal

Nesta seção, propomos um APP inexato com quase-distância, denotado por Algoritmo 1, para resolver o problema de otimização multiobjetivo irrestrito (POMI)

$$\text{MINIMIZE } \{F(x) \mid x \in \mathbb{R}^n\}, \tag{5}$$

onde $F = (F_1, F_2, \dots, F_m)^T : \mathbb{R}^n \rightarrow \mathbb{R}^m$ é uma aplicação convexa, i.e., $F_i : \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa, para todos $i \in \{1, \dots, m\}$. A sequência $\{x^k\} \subset \mathbb{R}^n$ é gerada como segue:

Algoritmo 1

1. Escolha $x^0 \in \mathbb{R}^n$.
2. Dado x^k , se $x^k \in \text{argmin}_w \{F(x) \mid x \in \mathbb{R}^n\}$, então $x^{k+p} = x^k, \forall p \geq 1$.
3. Dado x^k , se $x^k \notin \text{argmin}_w \{F(x) \mid x \in \mathbb{R}^n\}$, então tome como x^{k+1} qualquer vetor $x \in \Omega^k$ tal que existe $\varepsilon_k \in \mathbb{R}_+$ satisfazendo:

$$0 \in \partial_{\varepsilon_k}(\langle F(\cdot), z^k \rangle)(x) + \beta_k q(x, x^k) \partial(q(\cdot, x^k))(x) + N_{\Omega^k}(x), \tag{6}$$

$$q^2(x, x^k) \leq \bar{c} \|F(x) - F(x^k)\| \quad \text{and} \quad \lim_{k \rightarrow \infty} \varepsilon_k = 0. \tag{7}$$

onde $\partial_{\varepsilon_k}(\langle F(\cdot), z^k \rangle)(x)$ é a ε_k -subdiferencial da função convexa $\langle F(\cdot), z^k \rangle$ no ponto x , $N_{\Omega^k}(x)$ é o cone normal no ponto x em relação ao conjunto Ω^k , $0 < m < \beta_k < M$, $\{z^k\} \subset \mathbb{R}_+^m \setminus \{0\}$; $\|z^k\|_1 = 1$, $\bar{c} \in \mathbb{R}_+^*$ e $\Omega^k = \{x \in \mathbb{R}^n \mid F(x) \leq F(x^k)\}$.

Observação 3.1. a) Se $\{x^k\}$ for uma sequência gerada pelo algoritmo 1, então $\Omega^k \supseteq \Omega^{k+1}, \forall k$. Assim, $x^k \in \Omega^{k-1} \subseteq \Omega^0, \forall k \geq 1$. Portanto, Ω^0 limitado implica $\{x^k\}$ limitada, **b)** Se F possui uma de suas componentes coercivas, então Ω^0 é limitado ([9, Lema 4.1]).

Em seguida, vamos enunciar e provar o nosso principal resultado de convergência.

Teorema 3.1. Considere $F : \mathbb{R}^n \rightarrow \mathbb{R}^m$ convexa e $q : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}_+$ uma quase-distância que satisfaz a condição (4). Suponha que o conjunto Ω^0 seja limitado. Assim, se $\{x^k\}$ for uma sequência gerada pelo algoritmo 1, então $\{x^k\}$ é limitada e qualquer ponto de acumulação desta sequência é uma solução Pareto fraco para o POMI (5).

Demonstração. Dividimos a demonstração do Teorema em três etapas.

Etapa 1: Boa definição do algoritmo (Existência das iteradas). $x^0 \in \mathbb{R}^n$ é escolhido na etapa de inicialização. Supondo que o algoritmo atingiu a iteração k , vamos mostrar que um apropriado x^{k+1} existe. Pelo critério de parada, se $x^k \in \text{argmin}_w \{F(x), x \in \mathbb{R}^n\}$ então $x^{k+p} = x^k, \forall p \geq 1$. Por outro lado, defina $\varphi^k : \mathbb{R}^n \rightarrow \mathbb{R}$ tal que $\varphi^k(x) = \langle F(x), z^k \rangle + \frac{\beta_k}{2} q^2(x, x^k)$. A convexidade de F em \mathbb{R}^n implica na convexidade de $\langle F(\cdot), z^k \rangle$ em \mathbb{R}^n e então que $\langle F(\cdot), z^k \rangle$ é uma aplicação contínua em \mathbb{R}^n . Pela proposição 2.1, $q^2(\cdot, x^k) : \mathbb{R}^n \rightarrow \mathbb{R}_+$ é uma aplicação contínua. Logo, $\varphi^k : \mathbb{R}^n \rightarrow \mathbb{R}$ é uma aplicação contínua em \mathbb{R}^n . Desde que F é convexa em \mathbb{R}^n , $\Omega^k \supseteq \Omega^{k+1}, \forall k$ e Ω^0 é limitado (hipótese), temos que o conjunto $\Omega^k, \forall k$ é convexo e compacto. Portanto, o conjunto $\text{argmin}\{\varphi^k(x) \mid x \in \Omega^k\}$ é não vazio.

Seja $x^{k+1} \in \operatorname{argmin}\{\varphi^k(x) \mid x \in \Omega^k\}$. Então, pela observação 2.2,

$$0 \in \partial(\langle F(\cdot), z^k \rangle + \frac{\beta_k}{2} q^2(\cdot, x^k) + \delta_{\Omega^k})(x^{k+1}). \tag{8}$$

Desde que $\langle F(\cdot), z^k \rangle : \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa, $\langle F(\cdot), z^k \rangle$ é localmente Lipschitziana em \mathbb{R}^n ; pela proposição 2.1, $\frac{\beta_k}{2} q^2(\cdot, x^k)$ é localmente Lipschitziana em \mathbb{R}^n ; Ω^k fechado implica que δ_{Ω^k} é semi-contínua inferiormente (conf. [12, page 11]). Então, usando o Teorema 2.33 de [6] in (8), obtemos

$$0 \in \partial(\langle F(\cdot), z^k \rangle)(x^{k+1}) + \partial(\frac{\beta_k}{2} q^2(\cdot, x^k))(x^{k+1}) + \partial(\delta_{\Omega^k})(x^{k+1}). \tag{9}$$

Desde que Ω^k é convexo e $x^{k+1} \in \Omega^k$ temos $\partial(\delta_{\Omega^k})(x^{k+1}) = N_{\Omega^k}(x^{k+1})$, onde $N_{\Omega^k}(x^{k+1})$ denota o cone normal no ponto x^{k+1} em relação ao conjunto Ω^k . Pela proposição 2.1, $q(\cdot, x^k)$ é Lipschitziana em \mathbb{R}^n . Portanto, como $q(x, y) \geq 0; \forall(x, y) \in \mathbb{R}^n \times \mathbb{R}^n$, tomando $\varphi_1 = \varphi_2 = q(\cdot, x^k)$ no Teorema 7.1 de [7], obtemos $\partial(\frac{\beta_k}{2} q^2(\cdot, x^k))(x^{k+1}) = \beta_k q(x^{k+1}, x^k) \partial(q(\cdot, x^k))(x^{k+1})$, e então de (9),

$$0 \in \partial(\langle F(\cdot), z^k \rangle)(x^{k+1}) + \beta_k q(x^{k+1}, x^k) \partial(q(\cdot, x^k))(x^{k+1}) + N_{\Omega^k}(x^{k+1}).$$

Assim, desde que $\partial f(x) = \partial_0 f(x) \subset \partial_\varepsilon f(x)$ para toda função convexa $f : \mathbb{R}^n \rightarrow \mathbb{R}$, todo $x \in \mathbb{R}^n$ e todo $\varepsilon \in \mathbb{R}_+$, x^{k+1} satisfaz (6) para $\varepsilon_k \equiv 0$. Como $x^{k+1} \in \operatorname{argmin}\{\varphi^k(x) \mid x \in \Omega^k\}$ e $x^k \in \Omega^k; \forall k, \varphi^k(x^{k+1}) \leq \varphi^k(x^k); \forall k$. Portanto, desde que $q(x^k, x^k) = 0$, temos

$$\langle F(x^{k+1}), z^k \rangle + \frac{\beta_k}{2} q^2(x^{k+1}, x^k) \leq \langle F(x^k), z^k \rangle.$$

Então, como $0 < m < \beta_k, \|z^k\| \leq \|z^k\|_1$ e $\|z^k\|_1 = 1$, temos

$$0 \leq q^2(x^{k+1}, x^k) \leq \frac{2}{m} \langle F(x^k) - F(x^{k+1}), z^k \rangle \leq \frac{2}{m} \|F(x^k) - F(x^{k+1})\|.$$

Portantanto x^{k+1} satisfies (6) and (7).

Etapa 2: Propriedades. Seja $\{x^k\}$ uma seqüência gerada pelo algoritmo 1. Temos:

- (a) $\{x^k\}$ é limitada; (b) $\forall z \in \mathbb{R}_+^m \setminus \{0\}, \{\langle F(x^k), z \rangle\}_{k \in \mathbb{N}}$ é não crescente e convergente;
- (c) $\lim_{k \rightarrow \infty} \|F(x^{k+1}) - F(x^k)\| = 0;$ (d) $\lim_{k \rightarrow \infty} q(x^{k+1}, x^k) = 0;$ (e) $\lim_{k \rightarrow \infty} \|x^{k+1} - x^k\| = 0.$

De fato: (a) Desde que $\Omega^k \supseteq \Omega^{k+1}, k = 0, 1, \dots$, temos $x^k \in \Omega^{k-1} \subseteq \Omega^0, \forall k \geq 1$. Então, como Ω^0 é limitado (por hipótese), temos $\{x^k\}$ limitada.

(b) Desde que $F(x^{k+1}) \leq F(x^k) (x^{k+1} \in \Omega^k)$ e $z \in \mathbb{R}_+^m \setminus \{0\}$ temos:

$$\langle F(x^{k+1}), z \rangle \leq \langle F(x^k), z \rangle \quad \forall k \in \mathbb{N},$$

i.e., $\{\langle F(x^k), z \rangle\}_{k \in \mathbb{N}}$ é não crescente. Pela observação 2.1, $\{\langle F(x^k), z \rangle\}_{k \in \mathbb{N}}$ é limitada inferiormente e portanto convergente.

(c) Seja $\bar{z} \in \mathbb{R}_+^m$ fixado. Por (b), $\{\langle F(x^k), \bar{z} \rangle\}_{k \in \mathbb{N}}$ é convergente. Então,

$$\lim_{k \rightarrow \infty} \langle F(x^k) - F(x^{k+1}), \bar{z} \rangle = \lim_{k \rightarrow \infty} \sum_{i=1}^m (F_i(x^k) - F_i(x^{k+1})) \bar{z}_i = 0. \tag{10}$$

Como $x^{k+1} \in \Omega^k$, temos $F(x^{k+1}) \leq F(x^k)$, i.e., $F_i(x^{k+1}) \leq F_i(x^k), \forall i = 1, \dots, m$. Então $(F_i(x^k) - F_i(x^{k+1})) \bar{z}_i \geq 0, \forall i = 1, \dots, m$. Logo, de (10),

$$\lim_{k \rightarrow \infty} (F_i(x^k) - F_i(x^{k+1}))\bar{z}_i = 0, \forall i = 1, \dots, m.$$

Desde que $\bar{z}_i > 0, i = 1, \dots, m$, temos $\lim_{k \rightarrow \infty} (F_i(x^k) - F_i(x^{k+1})) = 0, \forall i = 1, \dots, m$, e então

$$\lim_{k \rightarrow \infty} (F(x^k) - F(x^{k+1})) = 0 \in \mathbb{R}^m. \text{ Portanto } \lim_{k \rightarrow \infty} \|F(x^{k+1}) - F(x^k)\| = 0.$$

(d) Por (7), $q^2(x^{k+1}, x^k) \leq \bar{c} \|F(x^{k+1}) - F(x^k)\|$. Assim, desde que $q(x, y) \geq 0$, o resultado segue do item (c).

(e) De (4), $0 \leq \alpha \|x^{k+1} - x^k\| \leq q(x^{k+1}, x^k), \forall k \in N$. Portanto, o resultado é uma consequência do item anterior.

Etapa 3: Convergência para Pareto fraco. Seja $\{x^k\}$ uma sequência gerada pelo algoritmo 1. Pela etapa 2 (item a), existem $x^* \in \mathbb{R}^n$ e $\{x^{k_j}\}_{j \in \mathbb{N}}$, uma subsequência de $\{x^k\}$, tal que $\lim_{j \rightarrow \infty} x^{k_j} = x^*$. Como $\|z^k\|_1 = 1, \forall k \in N$, existem $\bar{z} \in \mathbb{R}_+^m \setminus \{0\}$ e $\{z^{k_l}\}_{l \in \mathbb{N}}$, uma subsequência de $\{z^k\}$, tal que $\lim_{l \rightarrow \infty} z^{k_l} = \bar{z}$. Fixe $z \in \mathbb{R}_+^m \setminus \{0\}$. A Convexidade da aplicação $\langle F(\cdot), z \rangle$ em \mathbb{R}^n implica em sua continuidade. Pela etapa 2(b), $\forall z \in \mathbb{R}_+^m \setminus \{0\}; \{\langle F(x^k), z \rangle\}_{k \in \mathbb{N}}$ é não crescente e convergente. Portanto, $\forall z \in \mathbb{R}_+^m \setminus \{0\}; \lim_{j \rightarrow \infty} \langle F(x^{k_j}), z \rangle = \langle F(x^*), z \rangle = \inf_{k \in N} \{\langle F(x^k), z \rangle\}$. Então,

$$\langle F(x^*), z \rangle \leq \langle F(x^k), z \rangle, \forall z \in \mathbb{R}_+^m \setminus \{0\} \text{ and } k \in \mathbb{N}. \tag{11}$$

Por (6), existem $\zeta^{k_l+1} \in \partial(q(\cdot, x^{k_l}))(x^{k_l+1})$ e $v^{k_l+1} \in N_{\Omega^{k_l}}(x^{k_l+1})$, tal que

$$-\beta_{k_l} q(x^{k_l+1}, x^{k_l}) \zeta^{k_l+1} - v^{k_l+1} \in \partial_{\varepsilon_{k_l}}(\langle F(\cdot), z^{k_l} \rangle)(x^{k_l+1}).$$

Assim, pela desigualdade do ε_{k_l} -subgradiente para a função convexa $\langle F(\cdot), z^{k_l} \rangle$ temos: $\forall x \in \mathbb{R}^n$,

$$\langle F(x), z^{k_l} \rangle \geq \langle F(x^{k_l+1}), z^{k_l} \rangle - \beta_{k_l} q(x^{k_l+1}, x^{k_l}) \langle \zeta^{k_l+1}, x - x^{k_l+1} \rangle - \langle v^{k_l+1}, x - x^{k_l+1} \rangle - \varepsilon_{k_l}.$$

Como $v^{k_l+1} \in N_{\Omega^{k_l}}(x^{k_l+1})$, temos $-\langle v^{k_l+1}, x - x^{k_l+1} \rangle \geq 0 \forall x \in \Omega^{k_l}$. Por (H1) e (H2), $\Omega^k, \forall k \in \mathbb{N}$ é um conjunto compacto. Portanto, como $\Omega^{k+1} \subseteq \Omega^k, \forall k \in \mathbb{N}$ temos $\Omega = \bigcap_{k=0}^{\infty} \Omega^k \neq \emptyset$. Logo, em particular,

$$\langle F(x), z^{k_l} \rangle \geq \langle F(x^{k_l+1}), z^{k_l} \rangle - \beta_{k_l} q(x^{k_l+1}, x^{k_l}) \langle \zeta^{k_l+1}, x - x^{k_l+1} \rangle - \varepsilon_{k_l}, \forall x \in \Omega. \tag{12}$$

De (11), $\langle F(x^{k_l+1}), z^{k_l} \rangle \geq \langle F(x^*), z^{k_l} \rangle$. Então, de (12),

$$\langle F(x), z^{k_l} \rangle \geq \langle F(x^*), z^{k_l} \rangle - \beta_{k_l} q(x^{k_l+1}, x^{k_l}) \langle \zeta^{k_l+1}, x - x^{k_l+1} \rangle - \varepsilon_{k_l}, \forall x \in \Omega. \tag{13}$$

Pela proposição 2.2, $\|\zeta^{k_l+1}\| \leq M$. Portanto, como as sequências $\{x^k\}$ e $\{\beta_k\}$ são limitadas, utilizando a desigualdade de Cauchy-Swartz, concluímos que $|\beta_{k_l} \langle \zeta^{k_l+1}, x - x^{k_l+1} \rangle| \leq M_1$. Logo, desde que pela etapa 2 item d), $\lim_{k \rightarrow \infty} q(x^{k+1}, x^k) = 0$, temos

$$|\beta_{k_l} q(x^{k_l+1}, x^{k_l}) \langle \zeta^{k_l+1}, x - x^{k_l+1} \rangle| \rightarrow 0 \text{ quando } l \rightarrow \infty.$$

Portanto, recordando que $\lim_{l \rightarrow \infty} z^{k_l} = \bar{z}$, from (13)

$$\langle F(x), \bar{z} \rangle \geq \langle F(x^*), \bar{z} \rangle, \forall x \in \Omega. \tag{14}$$

Vamos demonstrar que $x^* \in \operatorname{argmin}_w \{F(x) \mid x \in \mathbb{R}^n\}$. Suponha, por contradição, que existe $\bar{x} \in \mathbb{R}^n$ tal que

$$F(\bar{x}) \ll F(x^*). \quad (15)$$

Como $\bar{z} \in \mathbb{R}_+^m \setminus \{0\}$ temos:

$$\langle F(\bar{x}), \bar{z} \rangle < \langle F(x^*), \bar{z} \rangle. \quad (16)$$

Desde que, $\Omega^{k+1} \subseteq \Omega^k$, $\forall k \geq 0$ e $x^{k_j} \in \Omega^{k_j-1}$, $\forall j$ com $x^{k_j} \rightarrow x^*$; $j \rightarrow \infty$, temos $x^* \in \Omega$, i.e., $F(x^*) \leq F(x^k)$, $\forall k \in \mathbb{N}$. Portanto, de (15), $F(\bar{x}) \ll F(x^k)$, $\forall k \in \mathbb{N}$, i.e., $\bar{x} \in \Omega$, que contradiz (14) e (16). \square

4 Conclusões

Propomos uma versão inexata do algoritmo proximal (AP) de Rocha et al. [10] que resolve problemas de otimização multiobjetivo convexo e irrestrito. Baseados em resultados de análise convexa e programação multiobjetivo e em técnicas avançadas de análise variacional não convexa e diferenciação generalizada, desenvolvemos uma completa análise de convergência do APP inexato para soluções Pareto fraco.

Como pesquisas futuras, pretendemos investigar a convergência do algoritmo para soluções Pareto (em vez de Pareto fraco) e propor uma implementação do algoritmo e assim, testa-lo através de diversos exemplos numéricos.

Referências

- [1] G. C. Bento, J. X. Cruz Neto, A. Soubeyran, *A Proximal Point-Type Method for Multicriteria Optimization*, Set-Valued Var. Anal, 22: 557-573, 2014.
- [2] H. Bonnel, A.N. Iusem, B.F. Svaiter, *Proximal methods in vector optimization*, SIAM Journal on Optimization, 15: 953-970, 2005 .
- [3] V. Brattka, *Recursive quasi-metric spaces*, Theoretical Computer Science, 305: 17-42, 2003.
- [4] X.X. Huang, X.Q. Yang, *Duality for multiobjective optimization via nonlinear Lagrangian functions*, Journal of Optimization Theory and Applications, 120: 111-127, 2004.
- [5] B. Martinet, *Régularization d'inéquations variationnelles par approximations successives*, Revue Française d'informatique et Recherche Operationelle, 4: 154-159, 1970.
- [6] B.S. Mordukhovich. *Variational Analysis and Generalized Differentiation I*. Springer, Berlin, 2006.
- [7] B.S. Mordukhovich, Y. Shao, *Nonsmooth sequential analysis in asplund spaces*, Transactions of the American Mathematical Society, 348: 1235-1280, 1996.
- [8] F.G. Moreno, P.R. Oliveira, A. Soubeyran, *A proximal algorithm with quasi distance. Application to habit's formation*, Optimization, 61: 1383-1403, 2012.
- [9] R.A.Rocha, P.R.Oliveira, R.M.Gregório, M.Souza, *Logarithmic quasi-distance proximal point scalarization method for multi-objective programming*, Applied Mathematics and computation, 273: 856-867, 2016.
- [10] R.A.Rocha, P.R.Oliveira, R.M.Gregório, M.Souza, *A proximal point algorithm with quasi-distance in multi-objective optimization*, J. Optim. Theory Appl, 171: 964-979, 2016.
- [11] R.T. Rockafellar, *Monotone operators and the proximal point algorithm*, SIAM Journal of Control and Optimization, 14: 877-898, 1976.
- [12] R.T. Rockafellar, R.J-B Wets. *Variational Analysis*. Springer, Berlin, 1998.