

Otimização convexa

Aluno: Bruno Henrique Cervelin
Orientadora: Profa. Dra. Maria Aparecida Diniz Ehrhardt

DMA – IMECC – UNICAMP

Resumo

Recentemente otimização convexa tem se tornado uma ferramenta muito importante para a resolução de problemas de engenharia, graças à sua eficácia e confiabilidade. Neste relatório apresentamos resultados estudados sobre análise convexa e dualidade, formando uma base teórica sobre o assunto, e também apresentamos resultados sobre alguns métodos de pontos interiores, a fim de obtermos algumas formas de resolução dos problemas estudados.

1 Introdução

Funções convexas aparecem constantemente em problemas reais, tais funções possuem características muito importantes como por exemplo, todo o minimizador de funções convexas em um conjunto convexo é um minimizador global neste conjunto, no Capítulo 3 são apresentados resultados sobre funções convexas, conjuntos convexas e algumas condições necessárias (suficientes) para a otimalidade destas funções.

Frequentemente associamos um problema de otimização convexa com outro problema, o problema dual, que pode ser equivalente ao problema original, e também mais fácil de se resolver. No capítulo 4 apresentamos resultados sobre dualidade em problemas lineares (4.1) e também em problemas gerais (4.2).

A resolução de problemas convexas, muitas vezes, mesmo que irrestrito, se dá através de métodos iterativos. Geralmente estes são métodos de descida. No capítulo 5, tomando como referência principalmente [3] e [4], mostramos um método de descida muito eficiente, o Método das Barreiras.

2 Definições

Neste capítulo apresentaremos separadamente as definições que nos serão úteis ao longo deste trabalho.

DEFINIÇÃO 1 Dados $x^i \in \mathbb{R}^n$, $\alpha_i \in [0, 1]$, $i = 1 \dots, p$, tais que $\sum_{i=1}^p \alpha_i = 1$, o ponto $\sum_{i=1}^p \alpha_i x^i$ chama-se combinação convexa dos pontos x^i com parâmetros α_i .

DEFINIÇÃO 2 Um conjunto $D \subset \mathbb{R}^n$ é chamado conjunto convexo se para quaisquer $x \in D$, $y \in D$ e $\alpha \in [0, 1]$, $\alpha x + (1 - \alpha)y \in D$.

DEFINIÇÃO 3 Um conjunto $K \subset \mathbb{R}^n$ chama-se cone quando $\forall d \in K$ e $\forall t \in \mathbb{R}_+$, $td \in K$.

DEFINIÇÃO 4 O cone dual de um cone $K \subset \mathbb{R}^n$ é definido por

$$K^* = \{y \in \mathbb{R}^n | y^T d \leq 0, \forall d \in K\}.$$

DEFINIÇÃO 5 Dado um conjunto $D \subset \mathbb{R}^n$ qualquer, o fecho cônico de D , denotado por cone D , é o menor cone convexo em \mathbb{R}^n que contém D .

DEFINIÇÃO 6 Dizemos que $d \in \mathbb{R}^n$ é uma direção tangente em relação ao conjunto D no ponto $x^* \in D$ quando $\text{dist}(x^* + td, D) = o(t)^1$, $t \in \mathbb{R}_+$.

O conjunto de todas as direções tangentes em relação ao conjunto D que passam pelo ponto x , denotado por $\tau_D(x)$, é chamado cone tangente.

DEFINIÇÃO 7 Dizemos que $V_D(x)$, é um conjunto de direções viáveis², no ponto $x \in D$, em relação ao conjunto D se

$$V_D(x) = \{d \in \mathbb{R}^n | \exists \alpha \in \mathbb{R}_+ \text{ t.q. } x + \alpha d \in D\}.$$

DEFINIÇÃO 8 Se D é um conjunto convexo, f é função convexa em D se $\forall x \in D, y \in D$ e $\alpha \in [0, 1]$,

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

Se a desigualdade for estrita, f é uma função estritamente convexa. Se tivermos

¹ $f(t) = o(t)$ implica que a função $f : \mathbb{R}_+ \rightarrow \mathbb{R}$ possui a propriedade de que $\lim_{t \rightarrow 0^+} f(t)/t = 0$

²a expressão factível será utilizada neste texto com o mesmo significado de viável

$$f(\alpha x + (1 - \alpha)y) \geq \alpha f(x) + (1 - \alpha)f(y),$$

então a função é côncava.

DEFINIÇÃO 9 Seja $D \subset \mathbb{R}^n$ um conjunto qualquer. O fecho convexo de D , denotado $\text{conv } D$, é o menor conjunto convexo em \mathbb{R}^n que contém D .

DEFINIÇÃO 10 Dizemos que $d \in \mathbb{R}^n$ é uma direção de recessão do conjunto convexo D quando $\forall t \in \mathbb{R}_+$ e $\forall x \in D$, $x + td \in D$.

DEFINIÇÃO 11 Dizemos que o hiperplano $H(a, c) = \{x \in \mathbb{R}^n | a^T x = c\}$, $a \neq 0$, separa os conjuntos D_1 e D_2 se

$$\begin{aligned} a^T x^1 &\leq c \leq a^T x^2 \\ \forall x^1 &\in D_1, \\ \forall x^2 &\in D_2. \end{aligned}$$

Se tivermos desigualdade estrita dizemos que o hiperplano separa estritamente D_1 e D_2 .

DEFINIÇÃO 12 O ponto x é ponto extremo do conjunto convexo D quando não pode ser representado por uma combinação convexa de outros pontos de D . O conjunto de todos os pontos extremos é denotado por $E(D)$.

DEFINIÇÃO 13 Seja f uma função convexa. Dizemos que $y \in \mathbb{R}^n$ é subgradiente de f no ponto x se

$$f(z) \geq f(x) + y^T(z - x) \forall z.$$

O conjunto de todos os subgradientes de f em x , denotado por $\partial f(x)$, chama-se subdiferencial de f em x .

DEFINIÇÃO 14 Dizemos que $(\bar{x}, \bar{y}) \in A \times B$ é um ponto de sela de uma função $f: A \times B \rightarrow \mathbb{R}$ quando

$$\begin{aligned} f(\bar{x}, y) &\leq f(\bar{x}, \bar{y}) \leq f(x, \bar{y}) \\ \forall x &\in A \text{ e } \forall y \in B. \end{aligned}$$

3 Elementos da Análise Convexa

Neste capítulo apresentamos os resultados estudados sobre análise convexa, As demonstrações para os fatos apresentados podem ser encontrados em [1].

Começamos nosso estudo com algumas propriedades dos conjuntos convexos.

- A intersecção de conjuntos convexos é um conjunto convexo;
- O fecho e o interior de um conjunto convexo são convexos;
- Se D_1 e D_2 são conjuntos convexos fechados e um deles é limitado então $D_1 + D_2$ é convexo e fechado;
- Um conjunto é convexo se, e somente se, todo ponto desse conjunto puder ser escrito como combinação convexa de outros pontos do conjunto.

Com estas propriedades obtemos que um conjunto poliedral é convexo, ou seja, conjuntos delimitados por restrições lineares são convexos.

Se D for um conjunto convexo, fechado e não vazio e R_D for o conjunto de todas as direções de recessão do conjunto D então:

- R_D é um cone convexo, fechado e não vazio.
- $d \in R_D$ se, e somente se, $\exists x \in D$ t.q. $x + td \in D \forall t \in \mathbb{R}_+$.
- $R_D \neq 0$ se, e somente se, D é ilimitado.

Estudamos também propriedades sobre fechos convexos:

- O fecho convexo de um conjunto qualquer é o conjunto de todas as combinações convexas de pontos deste conjunto;
- O fecho convexo de um conjunto compacto é compacto;
- O dual de um cone é igual ao dual de seu fecho convexo;

Estudamos alguns fatos sobre cones duais e fechos cônicos:

- O cone dual de um cone não vazio sempre é convexo e fechado;
- O fecho cônico de um conjunto convexo pode ser escrito como

$$\text{cone } D = \{d \in \mathbb{R}^n \mid d = \alpha x, x \in D, \alpha \in \mathbb{R}_+\};$$

- O cone tangente de um conjunto convexo pode ser escrito como

$$\tau_D(x^*) = \text{cl } V_d(x^*) = \text{cl } \text{cone}(D - \{x^*\}),$$

onde $\text{cl } D$ = fecho do conjunto D ;

- O cone tangente, de um conjunto convexo, é convexo e fechado;
- O cone e seu fecho possuem o mesmo dual.

Com essas propriedades conseguimos condições necessárias de primeira ordem de otimalidade para um problema com conjunto viável convexo:

TEOREMA 1 *Sejam $D \subset \mathbb{R}^n$ um conjunto convexo e $f : \mathbb{R}^n \rightarrow \mathbb{R}$ uma função diferenciável no ponto $x^* \in D$, se x^* é um minimizador local de f no conjunto D , então*

$$(x - x^*)^T \nabla f(x^*) \geq 0 \quad \forall x \in D.$$

Se f é convexa, então esta condição também é suficiente.

Quando D é um conjunto convexo e f é uma função convexa em D também convexo, dizemos que

$$\begin{aligned} & \min f(x) \\ & \text{s.a } x \in D \end{aligned}$$

é um *problema de minimização convexa*, e vimos que todo minimizador deste problema é global, e ainda, se f for estritamente convexa o minimizador é único.

Como estudamos problema com funções convexas, vimos algumas propriedades básicas destas:

- A soma de múltiplos não negativos de um número finito de funções convexas é uma função convexa;
- O supremo de funções convexas é uma função convexa;

- Se g é uma função convexa e h é uma função convexa e não decrescente, então $f(x) = g(h(x))$ também é convexa;
- Os conjuntos de níveis de uma função convexa são convexos;
- Uma função convexa é contínua em qualquer subconjunto aberto de seu domínio.

Fazendo uma extensão da definição de funções convexas com imagem em \mathbb{R} para funções com imagem em \mathbb{R}^m , temos que uma função é convexa se todas as suas componentes forem funções convexas. Daí chegamos à conclusão que um conjunto definido por funções convexas, na forma de inequações, e funções afins, na forma de equações, é um conjunto convexo.

Se a função $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é fortemente convexa no \mathbb{R}^n , então seu conjunto de nível

$$L_{f, \mathbb{R}^n}(c) = \{x \in \mathbb{R}^n | f(x) \leq c\}$$

é compacto para todo $c \in \mathbb{R}$.

Desta afirmação tiramos que uma função fortemente convexa tem um, e apenas um, minimizador em um conjunto fechado não vazio qualquer.

Vimos que se o conjunto de nível de uma função convexa é não vazio e limitado para alguma constante, então este conjunto de nível é limitado para qualquer constante.

Se estivermos maximizando uma função convexa sobre um conjunto convexo, então temos uma solução que é um ponto extremo do conjunto convexo. Logo se temos um problema de minimização em programação linear, como o $\min(c^T x) = -\max(-c^T x)$, uma solução ótima é um ponto extremo do conjunto viável.

Se f é uma função diferenciável em $D \subset \mathbb{R}^n$ convexo e aberto, as seguintes propriedades são equivalentes.

- f é convexa em D .
- $\forall x \in D$ e $\forall y \in D$, $f(y) \geq f(x) + (\nabla f(x))^T(y - x)$.
- $\forall x \in D$ e $\forall y \in D$, $(\nabla f(y) - \nabla f(x))^T(y - x) \geq 0$.
- A Hessiana de f é semidefinida positiva em todo ponto em D (Se f for duas vezes diferenciável em D).

Podemos apresentar agora as condições necessárias e suficientes para problemas de minimização convexa.

TEOREMA 2 *Sejam $D \subset \mathbb{R}^n$ um conjunto convexo e $f : C \rightarrow \mathbb{R}$ uma função convexa e diferenciável no conjunto aberto C que contém D . Então x^* é um minimizador de f em D se, e somente se,*

$$(\nabla f(x^*))^T(x - x^*) \geq 0 \forall x \in D,$$

que é equivalente a

$$(\nabla f(x))^T(x - x^*) \geq 0 \forall x \in D.$$

Ou, equivalentemente, se D é fechado,

$$x^* = P_D(x^* - \alpha \nabla f(x^*)) \text{ para algum } \alpha > 0.$$

O gradiente da função objetivo em um problema de minimização convexa é constante no conjunto das soluções. Daí pode ser provado que o conjunto de soluções de um problema de programação quadrática é um conjunto poliedral.

Se f é convexa, então

$$f(x + \alpha d) \geq f(x) + \alpha \nabla_d f(x), \forall \alpha \in \mathbb{R}_+,$$

onde d é uma direção de \mathbb{R}^n e $\nabla_d f(x)$ é a derivada direcional na direção d .

Vimos que a derivada direcional de uma função é semicontínua superiormente, e que se uma função convexa é diferenciável, então a sua derivada é contínua.

Vemos que o subdiferencial de uma função convexa definida em todo espaço é um conjunto convexo, compacto e não vazio em cada ponto.

Temos que f é uma função convexa e diferenciável no ponto x se, e somente se, o subdiferencial neste ponto possui apenas um elemento.

Com estas informações conseguimos obter uma condição de otimalidade para minimização de uma função convexa num conjunto convexo:

TEOREMA 3 *Sejam f uma função convexa e D um conjunto convexo. Então $x^* \in \mathbb{R}^n$ é um minimizador de f em D se, e somente se,*

$$\exists y \in \partial f(x^*) \text{ tal que } y^T(x - x^*) \geq 0 \forall x \in D.$$

Podemos ver que o subdiferencial de uma função convexa é limitado em conjuntos limitados. E que se f é uma função convexa, a sequência $\{x^k\}$ converge para x e $y^k \in \partial f(x) \forall k$, então a sequência $\{y^k\}$ é limitada e todos os seus pontos de acumulação pertencem ao subdiferencial de f no ponto x .

E ainda vimos que o subdiferencial da soma de funções convexas é a soma dos subdiferenciais destas funções.

Estudamos também uma outra forma para o Teorema 1, mas para chegar nela foi preciso antes estudar o operador projeção.

A projeção de um ponto x sobre um conjunto D é o ponto $y \in D$ tal que a distância, dada pela norma Euclidiana, entre x e y é mínima, ou seja, é o ponto y que satisfaz:

$$\begin{aligned} \min \|y - x\|_2 \\ \text{s.a } y \in D. \end{aligned}$$

Se $D \subset \mathbb{R}^n$ é fechado então todo $x \in \mathbb{R}^n$ possui uma projeção, denotada por $P_D(x)$, se D for convexo e fechado, então a projeção é única. Assim conseguimos a outra forma para o Teorema 1, que é mais útil, no sentido de aplicações a métodos computacionais.

TEOREMA 4 *Sejam $D \subset \mathbb{R}^n$ um conjunto convexo e fechado e $f : \mathbb{R}^n \rightarrow \mathbb{R}$ diferenciável no ponto $x^* \in D$.*

Se x^ é um minimizador local de f no conjunto D , então*

$$P_D(x^* - \alpha \nabla f(x^*)) = x^* \forall \alpha \in \mathbb{R}_+.$$

Quando f é convexa esta condição é também suficiente.

Estudamos alguns fatos sobre separação de conjuntos, tais como:

- se um ponto pertence à fronteira de um conjunto convexo, então ele pode ser separado deste conjunto;
- se um ponto não pertence ao fecho de um conjunto, então este ponto pode ser separado estritamente deste conjunto;
- dois conjuntos convexas, não vazios, com intersecção vazia são separáveis;
- se no item acima temos que os conjuntos são fechados e pelo menos um deles é limitado, então a separação é estrita.

Com estes fatos podemos demonstrar que o dual de um cone dual não vazio é o fecho convexo do cone primal.

Vimos que um conjunto convexo possui pelo menos um ponto extremo se, e somente se, ele não contém nenhuma reta.

Um conjunto convexo compacto é igual ao fecho convexo de seus pontos extremos, logo podemos dizer que todo ponto de um conjunto convexo compacto pode ser representado por uma combinação convexa de, no máximo, $n + 1$ de seus pontos extremos.

Vimos que em conjuntos delimitados por inequações lineares, ou seja, conjuntos com a forma

$$D = \{x \in \mathbb{R}^n | Ax \leq b\},$$

onde $A \in \mathbb{R}^{m \times n}$ e $b \in \mathbb{R}^m$, temos que x é ponto extremo de D se, e somente se, as linhas de A que correspondem às restrições ativas, ou seja, as restrições satisfeitas na igualdade, em x formam uma matriz de posto n .

Outra característica de um conjunto poliedral é que quando possui pontos extremos, ele pode ser gerado pela soma do fecho convexo de seus vértices com o cone de suas direções de recessão.

Estudamos também teoremas de alternativa, para isto tomamos dois sistemas de restrições lineares, equações e inequações, tais que um, e somente um, dos sistemas possui solução.

TEOREMA 5 *Teorema de Motzkin*

Para quaisquer matrizes $A_i \in \mathbb{R}^{m_i \times n}$, $i = 0, 1, 2$, um, e somente um, dos seguintes sistemas possui solução:

$$A_0x > 0, A_1x = 0, A_2x \geq 0, x \in \mathbb{R}^n,$$

ou

$$A_0^T y^0 + A_1^T y^1 + A_2^T y^2 = 0, \\ y^0 \in \mathbb{R}_+^{m_0} \setminus \{0\}, y^1 \in \mathbb{R}^{m_1}, y^2 \in \mathbb{R}_+^{m_2}.$$

Com o Teorema de Motzkin obtivemos o *Lema de Farkas*

LEMA 1 *Lema de Farkas*

Para qualquer matriz $A \in \mathbb{R}^{m \times n}$, um, e somente um, dos dois sistemas possui solução:

$$Ax \leq 0, b^T x > 0 \quad x \in \mathbb{R}^n,$$

ou

$$A^T y = b, y \in \mathbb{R}_+^m.$$

Com isto podemos obter as condições de otimalidade em forma primal-dual no caso de restrições lineares.

COROLÁRIO 1 *Seja $x^* \in \mathbb{R}^n$ uma solução local do problema*

$$\min f(x) \\ \text{s.a } Ax \leq b,$$

onde f é diferenciável em x^* , $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$.

Então existe $y^* \in \mathbb{R}_+^m$ tal que

$$\nabla f(x^*) + A^T y^* = 0, y_i^*, i \notin I(x^*),$$

onde $I(x)$ é o conjunto de índices das restrições ativas.

Foram estudados também outros teoremas de Alternativa, como o *Teorema da Alternativa de Tucker*, o *Teorema da Alternativa de Gale I* e *Teorema da Alternativa de Gordan*, que serão omitidos neste texto, pois os consideramos de menor importância para a perfeita compreensão do estudo do nosso tema. Estes resultados podem ser encontrados em [1].

4 Dualidade

Em problemas de otimização convexa podemos associar o problema original, primal, com um outro problema, o dual, que é sob certa perspectiva equivalente ao primal, e pode ser mais fácil de resolver. Começamos estudando a dualidade em problemas lineares e depois estudamos casos mais gerais para problemas não-lineares convexos. As demonstrações para os resultados apresentados neste capítulo podem ser encontrados em [1] e [2] por exemplo.

4.1 Dualidade em Programação Linear

Tomemos um problema de programação linear:

$$\begin{aligned} \min c^T x \\ \text{s.a } Ax \geq b, \end{aligned} \tag{1}$$

onde $A \in \mathbb{R}^{m \times n}$, $c \in \mathbb{R}^n$, $b \in \mathbb{R}^m$ e $x \in \mathbb{R}^n$, seu dual é dado por:

$$\begin{aligned} \max b^T y \\ \text{s.a } A^T y = c \\ y \geq 0 \end{aligned} \tag{2}$$

com $y \in \mathbb{R}^m$. Daí temos que se \bar{x} é viável para (1) e \bar{y} viável para (2), então $b^T \bar{y} \leq c^T \bar{x}$.

Esta desigualdade é chamada de dualidade fraca. Quando temos a igualdade os pontos \bar{x} e \bar{y} são ótimos; chamamos este fato de dualidade forte.

Para qualquer par primal-dual de programação linear temos uma destas possibilidades satisfeitas:

- Os dois problemas são infactíveis;
- Um dos problemas é ilimitado, então o outro é infactível;
- Um dos problemas é limitado não vazio, então os dois possuem solução.

4.2 Dualidade para um problema geral

Veremos, a seguir, algumas propriedades do dual para problemas não lineares. Consideremos um problema de minimização (não linear) na forma geral:

$$\begin{aligned} \min f(x) \\ \text{s.a } x \in D \\ D = \{x \mid g(x) \leq 0, h(x) = 0\} \end{aligned} \tag{3}$$

onde $x \in \mathbb{R}^n$, $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$ e $h : \mathbb{R}^n \rightarrow \mathbb{R}^l$. Chamamos o problema (3) de *problema primal*.

Usaremos a função *Lagrangeana* para produzir o dual deste problema, ou seja, passaremos as restrições do problema, com pesos, para a função objetivo. Assim podemos definir a Lagrangiana como

$$L(x, \lambda, \nu) = f(x) + \lambda^T h(x) + \nu^T g(x).$$

Primeiro vemos que

$$\sup_{(\lambda, \nu)} L(x, \lambda, \nu) = \begin{cases} f(x) & \text{se } x \in D, \\ \infty & \text{c.c} \end{cases}$$

Logo podemos escrever o primal como

$$\begin{aligned} & \min\{sup_{(\lambda,\nu)}L(x,\lambda,\nu)\} \\ \text{s.a } & x \in D = \{x \mid sup_{(\lambda,\nu)}L(x,\lambda,\nu) < \infty\}. \end{aligned} \quad (4)$$

Obtemos o *problema dual* trocando a ordem de minimização com a maximização, o que resulta em:

$$\begin{aligned} & \max\{inf_x L(x,\lambda,\nu)\} \\ \text{s.a } & (\lambda,\nu) \in \Delta = \{(\lambda,\nu) \mid inf_x L(x,\lambda,\nu) > -\infty\}. \end{aligned} \quad (5)$$

A *função dual* é definida como:

$$\phi(\lambda,\nu) = inf_x L(x,\lambda,\nu).$$

Daí obtemos uma outra forma de escrever o problema dual:

$$\begin{aligned} & \max \phi(\lambda,\nu) \\ \text{s.a } & (\lambda,\nu) \in \Delta. \end{aligned}$$

Um resultado importante obtido é que o conjunto viável Δ do problema dual é convexo e a função dual é côncava, independentemente da forma do problema primal, logo podemos escrever o problema dual como um problema de minimização convexa.

Outro resultado importante é a *dualidade fraca*, que nos diz que para todo par primal dual, temos

$$\begin{aligned} & \phi(\lambda,\nu) \leq f(x) \\ & \forall x \in D, (\lambda,\nu) \in \Delta. \end{aligned}$$

Tomando $p^* = inf_x f(x)$, $d^* = sup_{(\lambda,\nu)} \phi(\lambda,\nu)$, $x^* \in D$ e $(\lambda^*, \nu^*) \in \Delta$, tiramos do resultado acima que:

- Se $f(x^*) = d^*$, então x^* é solução do problema primal;
- Se $\phi(\lambda^*, \nu^*) = p^*$, então (λ^*, ν^*) é solução do problema dual;
- Se $f(x^*) = \phi(\lambda^*, \nu^*)$, então x^* é solução do problema primal e (λ^*, ν^*) é solução do problema dual.

Em problemas não lineares nem sempre podemos satisfazer esta terceira afirmação, ou seja, temos $d^* < p^*$, mas ainda assim podemos tirar conclusões bastante úteis do problema dual, como por exemplo, se $d^* = -\infty$ então o conjunto $D = \emptyset$, e também qualquer ponto viável do problema dual nos fornece um limitante inferior para o valor ótimo do problema primal.

Em um problema de minimização convexa, onde é satisfeita a condição de qualificação de Slater,

$$\exists \bar{x} \in \mathbb{R}^n \text{ t.q. } h(\bar{x}) = 0 \text{ e } g(\bar{x}) < 0, \quad (6)$$

temos que $d^* = p^*$, ou seja não há *gap de dualidade*.

Ainda considerando um problema de minimização convex satisfazendo (6), temos

TEOREMA 6 *Teorema de Kuhn-Tucker*
 $x^* \in D$ é uma solução do primal se, e somente se, existe $(\lambda^*, \nu^*) \in \mathbb{R}^l \times \mathbb{R}_+^m$ tal que

$$\begin{aligned} & L(x^*, \lambda^*, \nu^*) = min_x L(x, \lambda^*, \nu^*), \\ & \nu_i^* g_i(x^*) = 0, \quad i = 1, \dots, m. \end{aligned}$$

Usando ainda a definição de ponto de sela (definição 14), podemos reescrever a afirmação anterior dizendo que $x^* \in \mathbb{R}^n$ é uma solução do problema primal se, e somente se, existe $(\lambda^*, \nu^*) \in \mathbb{R}^l \times \mathbb{R}_+^m$ tal que (x^*, λ^*, ν^*) é um ponto de sela em $\mathbb{R}^n \times (\mathbb{R}^l \times \mathbb{R}_+^m)$.

Concluimos este capítulo com o fato que, se $(\lambda, \nu) \in \Delta$ e $x(\lambda, \nu) \in \mathbb{R}^n$ tais que

$$L(x(\lambda, \nu), \lambda, \nu) = \phi(\lambda, \nu) = min_{x \in \mathbb{R}^n} L(x, \lambda, \nu),$$

então

$$-(h(x(\lambda, \nu)), g(x(\lambda, \nu))) \in \partial(-\phi)(\lambda, \nu).$$

5 Métodos de Pontos Interiores

Nesta seção apresentaremos alguns métodos estudados para resolver problemas de otimização convexa, começamos estudando um método para resolver problemas irrestritos.

Tomando o problema

$$\min f(x), \quad (7)$$

onde $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa e duas vezes diferenciável, estamos supondo que existe solução para este problema, e que esta seja única.

Como f é convexa e diferenciável a condição, necessária e suficiente, para que x^* seja ótimo é que

$$\nabla f(x^*) = 0.$$

DEFINIÇÃO 15 $d \in \mathbb{R}^n$ é um direção de descida para f a partir de $x \in \mathbb{R}^n$ se existe \bar{t} tal que $f(x + td) < f(x)$ para todo $t \in (0, \bar{t}]$.

TEOREMA 7 Se f é diferenciável e $\nabla f(x)^T d < 0$, então d é direção de descida para f a partir de x .

Então usando uma sequência $x^{(k+1)} = x^{(k)} + t_k d^{(k)}$, com $d^{(k)} \in \mathbb{R}^n$ direções de descida e $0 < t_k \in \mathbb{R}$, temos um método de direção de descida:

Método de Descida Geral

Dados: $x^{(0)}$, $k = 0$, $\epsilon > 0$.

Repetir:

- Determinar uma direção de descida $d^{(k)}$.
- Escolher tamanho do passo $t_k > 0$, de modo que $f(x^{(k)} + t_k d^{(k)}) < f(x^{(k)})$.
- Fazer $x^{(k+1)} = x^{(k)} + t_k d^{(k)}$.
- Se $|f(x^{(k+1)}) - f(x^{(k)})| < \epsilon$, parar: $x^{(k+1)}$ é solução ótima.
- Fazer $k = k + 1$.

Outro método estudado foi o *Método de Newton*. Neste caso estaremos resolvendo problemas com restrições lineares de igualdade,

$$\begin{aligned} \min f(x) \\ \text{s.a } Ax = b, \end{aligned} \quad (8)$$

onde $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa e duas vezes diferenciável, $A \in \mathbb{R}^{m \times n}$, com posto $A = p < n$. (novamente estamos supondo que exista uma solução para o sistema).

Logicamente todo problema com restrições de igualdade podem ser resolvidos através de um problema irrestrito equivalente; aqui iremos resolver o problema com as restrições.

Temos que x^* é ótimo se, e somente se, $\exists \nu^* \in \mathbb{R}^m$

$$\begin{aligned} Ax^* &= b, \\ \nabla f(x^*) + A^T \nu^* &= 0. \end{aligned}$$

O método de Newton é amplamente utilizado em métodos de pontos interiores dada a sua rápida taxa de convergência, que vem do fato deste método utilizar informações da segunda derivada da função objetivo no cálculo das direções de descida. Esta direção de descida é escolhida de modo a minimizar uma aproximação quadrática da função objetivo na última iteração.

Quando, usamos uma aproximação quadrática no lugar de f , a direção de descida, d_{nt} , é dada por:

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} d_{nt} \\ w \end{bmatrix} = \begin{bmatrix} -\nabla f(x) \\ 0 \end{bmatrix}, \quad (9)$$

onde w é o valor ótimo da variável dual associada ao problema quadrático.

Definimos o decréscimo de Newton para um problema com restrições de igualdade como

$$\lambda(x) = (d_{nt}^T \nabla^2 f(x) d_{nt}).$$

Pode-se provar [2] que $\lambda(x)^2/2$ nos dá uma estimativa para $f(x) - p^*$ então $\lambda(x)$ pode ser utilizado como base de um critério de parada.

A direção d_{nt} é uma direção factível, ou seja, $Ad_{nt} = 0$, vemos isto pela segunda linha do sistema (9), e também é uma direção de descida pois a derivada direcional de f na direção d_{nt} é negativa, na verdade vale $-\lambda(x)^2$.

Método de Newton para problemas com restrições de igualdade

Dados: $x^{(0)}$ t.q. $Ax^{(0)} = b$, $k = 0$, $\epsilon > 0$.

Repetir:

- Determinar uma direção de Newton, $d_{nt}^{(k)}$, e o decréscimo, $\lambda(x^{(k)})$.
- Se $\lambda^2/2 \leq \epsilon$, parar.
- Escolher tamanho do passo $t_k > 0$, de modo que $f(x^{(k)} + t_k d_{nt}^{(k)}) < f(x^{(k)})$.
- Fazer $x^{(k+1)} = x^{(k)} + t_k d_{nt}^{(k)}$.
- Fazer $k = k + 1$.

Este método é chamado método de descida factível, já que toda iteração é factível, com $f(x^{(k+1)}) < f(x^{(k)})$.

Passamos então ao *Método das Barreiras* para resolução de problemas convexos com restrições de desigualdade,

$$\begin{aligned} \min f(x) \\ \text{s.a } g(x) \leq 0 \\ Ax = b, \end{aligned} \quad (10)$$

onde $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$ e $A \in \mathbb{R}^{p \times n}$. Assumimos que existe alguma solução ótima, e que existem pontos viáveis que satisfazem as desigualdades estritamente. Isto implica que as condições de Slater (6) são satisfeitas; logo existe ponto ótimo do dual, $(\lambda^*, \nu^*) \in \mathbb{R}^m \times \mathbb{R}^p$, que junto com o ótimo do primal, x^* , satisfaz as condições

$$\begin{aligned} Ax^* &= b \\ g(x^*) &\leq 0 \\ \lambda_i g_i(x^*) &= 0, \quad i = 1, \dots, m \\ \lambda^* &\geq 0 \\ \nabla f(x^*) + \lambda^T \nabla g(x^*) + A^T \nu^* &= 0. \end{aligned} \quad (11)$$

Os métodos de pontos interiores resolvem o problema (10) aplicando o método de Newton para uma sequência de problemas com restrição de igualdade. Nosso interesse é um tipo especial de método de pontos interiores, o método das barreiras.

Vamos então aproximar o problema (10) por um problema apenas com restrições de igualdade:

$$\begin{aligned} \min f(x) + (-1/t) \mathbf{1}^T \log(-f(x)) \\ \text{s.a } Ax = b. \end{aligned} \quad (12)$$

Definindo a função logaritmo para um vetor como o vetor cujas componentes são o logaritmo de cada componente do vetor original, o problema (12) tem função objetivo convexa e diferenciável.

A função

$$\phi(x) = \mathbf{1}^T \log(-f(x)),$$

com domínio em $\{x | f(x) < 0\}$, é chamada de barreira logarítmica.

Vemos que quanto maior for o valor da função objetiva em (12), melhor é a aproximação, porém mais difícil é a resolução do problema através do método de Newton.

O que faremos neste método é ir aumentando o valor de t , e resolvendo a cada iteração o problema resultante usando o método de Newton, com ponto inicial dado pela solução dada pela iteração anterior.

Definimos o *caminho central* como o conjunto formado por $x^*(t)$, $t > 0$, onde $x^*(t)$ é solução de (12), e podemos ver que $x^*(t)$ é estritamente factível para o problema original e existe $\bar{\nu} \in \mathbb{R}^p$, tal que

$$0 = t \nabla f(x^*(t)) + \nabla \phi(x^*(t)) + A^T \bar{\nu}$$

Com encontrando o gradiente de ϕ podemos encontrar um valor para a variável dual associada a cada ponto do caminho central:

$$\begin{aligned} \lambda_i(t) &= -\frac{1}{t f_i(x^*(t))} \quad i = 1, \dots, m, \\ \nu^*(t) &= \bar{\nu}/t, \end{aligned} \tag{13}$$

e este par, $(\lambda^*(t), \nu^*(t))$, é dual factível, e o gap de dualidade associado com $x^*(t)$ e $(\lambda^*(t), \nu^*(t))$ vale m/t .

Com isto podemos escrever o método em pseudo código:

Método das Barreiras

Dados: $x^{(0)}$ estritamente factível, $t_0 > 0$, $\mu_0 > 1$, $k = 0$, $\epsilon > 0$.

Repetir:

- Calcular $x^*(t_k)$ resolvendo o sistema dado por (12) começando com $x^{(k)}$.
- Fazer $x^{(k+1)} = x^*(t_k)$.
- Se $m/t < \epsilon$, parar.
- Fazer $t_{k+1} = \mu t_k$.
- Atualizar $k = k + 1$.

Este método exige que tenhamos um ponto estritamente factível como ponto inicial; aplicamos então um processo preliminar, chamado *Fase 1*. Para isto criamos o seguinte problema

$$\begin{aligned} \min s \\ \text{s.a } g(x) \leq s \mathbf{1} \\ Ax = b. \end{aligned} \tag{14}$$

onde $\mathbf{1}$ é um vetor com todas as componentes iguais a 1 e $s \in \mathbb{R}$. Esta variável é conhecida como infactibilidade máxima, e a meta é deixá-la abaixo de 0, de modo a conseguir $x^{(0)}$ estritamente factível para usarmos no problema original.

6 Conclusão

Portanto podemos ver os benefícios de se trabalhar com problemas convexos como, por exemplo, não termos que nos preocupar se o método utilizado está convergindo para um minimizador local, pois todo minimizador em um problema convexo é global. Outra vantagem é que temos as condições necessárias e suficientes de otimalidade bem definidas, o que também nos dá possibilidades de desenvolvimento de métodos para resolver estes problemas.

Trabalhar com o problema dual também oferece vantagens, tanto para problemas lineares quanto para problemas não lineares, uma destas vantagens são os métodos primal-dual, por exemplo o método das barreiras, que usam informações tanto do primal quanto do dual para resolver o problema de forma muito eficiente.

Mesmo quando não é possível aplicar um método primal-dual o dual nos é muito útil dado que a função objetivo do dual de qualquer problema é sempre uma função côncava, logo podemos transformá-la em uma função convexa e daí pela desigualdade fraca obteremos pelo menos um limitante para o valor ótimo do primal, e ainda se o gap de dualidade for nulo este será o valor ótimo do problema primal.

Referências

- [1] A. IZMAILOV, M. SOLODOV, *Otimização - volume 1*. IMPA, Rio de Janeiro, RJ, 2005.
- [2] S.P. BOYD, L. VANDENBERGHE, *Convex Optimization*. Cambridge University Press, 2004.
- [3] D.G. LUENBERGUER, Y.YE, *Linear and Nonlinear Programming*. Springer Verlag, 2008.
- [4] H. HINDI, A tutorial on convex optimization II: Duality and interior point methods, *American Control Conference*, 2006.