

Fundamentos de teoria quântica

Introdução a otimização convexa

Rafael Rabelo – rabelo@ifi.unicamp.br

Departamento de Física da Matéria Condensada
Instituto de Física “Gleb Wataghin”
Universidade Estadual de Campinas

Sejam dois pontos $x_1 \neq x_2$ de \mathbb{R}^n . Pontos da forma

$$y = \theta x_1 + (1 - \theta)x_2, \quad (1)$$

onde $\theta \in \mathbb{R}$, formam a *reta* que passam por x_1 e x_2 .

Para $0 \leq \theta \leq 1$, tem-se o *segmento de reta* entre x_1 e x_2 .

Um conjunto $C \subseteq \mathbb{R}^n$ é *afim* se a reta que passa entre quaisquer dois pontos em C está contida em C , ou seja, para $x_1, x_2 \in C$ e $\theta \in \mathbb{R}$,
 $\theta x_1 + (1 - \theta)x_2 \in C$.

Um ponto da forma

$$\theta_1 x_1 + \cdots + \theta_k x_k, \quad (2)$$

onde $\sum_{i=1}^k \theta_i = 1$ é uma *combinação afim* dos pontos x_1, \dots, x_k .

O conjunto de todas as combinações afins de $C \subseteq \mathbb{R}^n$ é chamado de *fecho afim de C*, denotado $\text{aff}(C)$:

$$\text{aff}(C) = \left\{ \theta_1 x_1 + \cdots + \theta_k x_k \mid x_1, \dots, x_k \in C; \sum_{i=1}^k \theta_i = 1 \right\}. \quad (3)$$

O fecho afim de C é o menor conjunto afim que contém C .

Um conjunto $C \subseteq \mathbb{R}^n$ é *convexo* se o segmento de reta que passa entre quaisquer dois pontos em C está contida em C , ou seja, para $x_1, x_2 \in C$ e $0 \leq \theta \leq 1$, $\theta x_1 + (1 - \theta)x_2 \in C$.

Um ponto da forma

$$\theta_1 x_1 + \cdots + \theta_k x_k, \quad (4)$$

onde $\theta_i \geq 0$, $\sum_{i=1}^k \theta_i = 1$, é uma *combinação convexa* dos pontos x_1, \dots, x_k .

Seja C um conjunto convexo. Um ponto $x \in C$ que não pode ser escrito como combinação convexa de outros pontos de C é dito *extremal*.

O conjunto de todas as combinações convexas de $C \subseteq \mathbb{R}^n$ é chamado de *fecho convexo de C*, denotado $\text{conv}(C)$:

$$\text{conv}(C) = \left\{ \sum_{i=1}^k \theta_i x_i \mid x_i \in C; \theta_i \geq 0, i = 1, \dots, k; \sum_{i=1}^k \theta_i = 1 \right\}. \quad (5)$$

O fecho convexo de C é o menor conjunto convexo que contém C .

Um conjunto $C \subseteq \mathbb{R}^n$ é um *cone* se para todo $x \in C$ e $\theta \geq 0$, $\theta x \in C$.

Um conjunto $C \subseteq \mathbb{R}^n$ é um *cone convexo* se é convexo e é um cone, ou seja, para todo par de pontos $x_1, x_2 \in C$ e $\theta_1, \theta_2 \geq 0$,

$$\theta_1 x_1 + \theta_2 x_2 \in C. \quad (6)$$

Um ponto da forma

$$\theta_1 x_1 + \cdots + \theta_k x_k, \quad (7)$$

onde $\theta_i \geq 0$, é uma *combinação cônica* dos pontos x_1, \dots, x_k .

O conjunto de todas as combinações cônicas de $C \subseteq \mathbb{R}^n$ é chamado de *fecho cônico de C* , denotado $\text{cone}(C)$:

$$\text{cone}(C) = \left\{ \sum_{i=1}^k \theta_i x_i \mid x_i \in C; \theta_i \geq 0, i = 1, \dots, k \right\}. \quad (8)$$

O fecho cônico de C é o menor cone que contém C .

Um *hiperplano* é um conjunto da forma

$$\{x | a^T x = b\}, \quad (9)$$

onde $a \in \mathbb{R}^n$, $a \neq 0$ e $b \in \mathbb{R}$.

Um hiperplano divide \mathbb{R}^n em dois *semi-espços*. Um semi-espço (fechado) é um conjunto da forma

$$\{x \mid a^T x \leq b\}, \quad (10)$$

onde $a \in \mathbb{R}^n$, $a \neq 0$ e $b \in \mathbb{R}$.

Um *bola euclidiana* em \mathbb{R}^n , centrada em x_c e de raio r , é o conjunto

$$B(x_c, r) = \{x \mid \|x - x_c\|_2 \leq r\}, \quad (11)$$

onde $r > 0$ e $\|\cdot\|_2$ denota a norma euclidiana.

Seja $\|\cdot\|$ uma norma em \mathbb{R}^n . Uma *bola da norma* em \mathbb{R}^n , centrada em x_c e de raio r , é o conjunto

$$B(x_c, r) = \{x \mid \|x - x_c\| \leq r\}, \quad (12)$$

onde $r > 0$.

Um *cone da norma* associado à norma $\|\cdot\|$ é o conjunto

$$C = \{(x, t) \mid \|x\| \leq t\} \subseteq \mathbb{R}^{n+1}. \quad (13)$$

Um *poliedro*, ou *politopo*, é o conjunto solução de um número finito de equações e desigualdades lineares:

$$P = \{x \mid a_i^T x \leq b_i, i = 1, \dots, m; c_j^T x = d_j, j = 1, \dots, p\}. \quad (14)$$

Em outros termos, é a interseção de um número finito de semi-espacos e hiperplanos.

É conveniente usar a forma compacta

$$P = \{x \mid Ax \preceq b, Cx = d\}, \quad (15)$$

onde

$$A = \begin{bmatrix} a_1^T \\ \vdots \\ a_m^T \end{bmatrix}, \quad C = \begin{bmatrix} c_1^T \\ \vdots \\ c_p^T \end{bmatrix}, \quad (16)$$

e o símbolo \preceq denota desigualdade elemento a elemento.

Uma forma equivalente de descrever um politopo P é como o fecho convexo de um conjunto finito de pontos $C = \{x_1, \dots, x_k\}$:

$$P = \text{conv}(C) = \{ \theta_1 x_1 + \dots + \theta_k x_k \mid \theta \succeq 0, \mathbf{1}^T \theta = 1 \}. \quad (17)$$

Denota-se por S^n o conjunto das *matrizes* $n \times n$ *simétricas*:

$$S^n = \{X \in \mathbb{R}^{n \times n} \mid X = X^T\}. \quad (18)$$

Este conjunto constitui um espaço vetorial real de dimensão $n(n+1)/2$.

Denota-se por S_+^n o conjunto das *matrizes $n \times n$ simétricas positivas semi-definidas*:

$$S_+^n = \{X \in S^n \mid X \succeq 0\}, \quad (19)$$

onde $X \succeq 0$ denota que, para todo $y \in \mathbb{R}^n$, $y^T X y \geq 0$.

O conjunto S_+^n é um cone, ou seja, se $\theta_1, \theta_2 \geq 0$ e $A, B \in S_+^n$, então

$$\theta_1 A + \theta_2 B \in S_+^n. \quad (20)$$

Sejam C e D dois conjuntos convexos que não se intersectam. Então existem $a \neq 0$ e b tais que $a^T x \leq b$ para todo $x \in C$ e $a^T y \geq b$ para todo $y \in D$.

O hiperplano $\{x \mid a^T x = b\}$ é dito *hiperplano separador* para os conjuntos C e D .

Uma função $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é *convexa* se $\text{dom } f$ é um conjunto convexo e se, para todo $x, y \in \text{dom } f$, e $0 \leq \theta \leq 1$:

$$f(\theta x + (1 - \theta)y) \leq \theta f(x) + (1 - \theta)f(y). \quad (21)$$

A função f é *estritamente convexa* se vale a desigualdade estrita para $x \neq y$ e $0 < \theta < 1$.

Uma função $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é (estritamente) *côncava* se $-f$ é (estritamente) convexa.

- Exponencial: e^{ax} é convexa em \mathbb{R} , para todo $a \in \mathbb{R}$.
- Potências: x^a é convexa em \mathbb{R}_{++} quando $a \geq 1$ ou $a \leq 0$, e côncava quando $0 \leq a \leq 1$.
- Potências do valor absoluto: $|x|^p$, para $p \geq 1$, é convexa em \mathbb{R} .
- Logaritmo: $\log(x)$ é côncava em \mathbb{R}_{++} .
- Normas: toda norma em \mathbb{R}^n é convexa.
- Função max: $f(x) = \max\{x_1, \dots, x_n\}$ é convexa em \mathbb{R}^n .
- Média geométrica: $f(x) = \left(\prod_{i=1}^n x_i\right)^{1/n}$ é côncava em \mathbb{R}_{++}^n .
- Log-determinante: $f(X) = \log(\det(X))$ é côncava em S_{++}^n .

Um *problema de otimização* pode ser formulado como

$$\text{minimize } f_0(x)$$

$$\text{sujeito a } f_i(x) \leq 0, i = 1, \dots, m$$

$$h_i(x) = 0, i = 1, \dots, p.$$

- $x \in \mathbb{R}^n$ é a *variável de otimização*;
- $f_0 : \mathbb{R}^n \rightarrow \mathbb{R}$ é a *função objetivo*;
- $f_i : \mathbb{R}^n \rightarrow \mathbb{R}$ são as *funções dos vínculos de desigualdade*;
- $h_i : \mathbb{R}^n \rightarrow \mathbb{R}$ são as *funções dos vínculos de igualdade*;

- o *domínio* do problema de otimização é

$$D = \bigcap_{i=0}^m \text{dom } f_i \cap \bigcap_{i=1}^p \text{dom } h_i; \quad (22)$$

- um ponto $x \in D$ é dito *factível* se satisfaz todos os vínculos;
- o *valor ótimo* do problema é definido como

$$p^* = \inf \{f_0(x) \mid f_i(x) \leq 0, i = 1, \dots, m; h_i(x) = 0, i = 1, \dots, p\}; \quad (23)$$

- um ponto x^* é dito *ótimo* se é factível e $f_0(x^*) = p^*$.

Um *problema de factibilidade* é formulado como

encontre x

sujeito a $f_i(x) \leq 0, i = 1, \dots, m$

$h_i(x) = 0, i = 1, \dots, p.$

Um *problema de otimização convexa* é um problema de otimização da forma

$$\begin{aligned} & \text{minimize} && f_0(x) \\ & \text{sujeito a} && f_i(x) \leq 0, i = 1, \dots, m \\ & && a_i^T x = b_i, i = 1, \dots, p; \end{aligned}$$

onde f_0, \dots, f_m são funções convexas.

Propriedade importante: todo ponto ótimo local é um ponto ótimo.

Um *programa linear (LP)* é um problema de otimização da forma

$$\begin{aligned} \text{minimize} \quad & c^T x + d \\ \text{sujeito a} \quad & Gx \preceq h \\ & Ax = b; \end{aligned}$$

onde $G \in \mathbb{R}^{m \times n}$ e $A \in \mathbb{R}^{p \times n}$.

Programas lineares são problemas de otimização convexa.

Um *programa semi-definido (SDP)* é um problema de otimização da forma

$$\begin{aligned} & \text{minimize} && \text{Tr}(CX) \\ & \text{sujeito a} && \text{Tr}(A_i X) = b_i, \quad i = 1, \dots, p \\ & && X \succeq 0; \end{aligned}$$

onde $X, C, A_1, \dots, A_p \in S^n$, e $\text{Tr}(\cdot)$ denota o traço de uma matriz quadrada, definido como a soma dos elementos de sua diagonal principal.

Programas semidefinidos também são problemas de otimização convexa.

Considere um problema de otimização

$$\begin{aligned} &\text{minimize} && f_0(x) \\ &\text{sujeito a} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && h_i(x) = 0, \quad i = 1, \dots, p; \end{aligned}$$

onde $x \in \mathbb{R}^n$. Define-se o *Lagrangiano* $L : \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R}$ associado ao problema como

$$L(x, \lambda, \nu) = f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p \nu_i h_i(x). \quad (24)$$

As variáveis $\lambda \in \mathbb{R}^m$ e $\nu \in \mathbb{R}^p$ são chamadas *multiplicadores de Lagrange*.

Dado um Lagrangiano L associado a um problema de otimização, sua *função dual (de Lagrange)* $g : \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R}$ é definida como

$$g(\lambda, \nu) = \inf_{x \in D} L(x, \lambda, \nu). \quad (25)$$

Para todo $\lambda \succeq 0$ e todo ν , $g(\lambda, \nu) \leq p^*$.

O problema dual de Lagrange

O *problema dual de Lagrange*, dado um problema *primal*, é

$$\begin{aligned} &\text{maximize} && g(\lambda, \nu) \\ &\text{sujeito a} && \lambda \succeq 0. \end{aligned}$$

O problema dual é sempre um problema de otimização convexa, independentemente do problema primal.

Sejam p^* o valor ótimo do problema primal e d^* o valor ótimo do problema dual. Então

$$d^* \leq p^*. \quad (26)$$

Dualidade fraca vale mesmo que o problema primal não seja convexo.

Em geral, quando o problema primal é convexo, vale a *dualidade forte*

$$d^* = p^*. \quad (27)$$

Assim, para problemas de otimização convexa, em geral é possível saber se o valor ótimo foi alcançado ou não resolvendo-se ambos os problemas primal e dual, e avaliando-se a diferença entre as soluções obtidas.