

MCTA017 – Programação Matemática

**EPR202 – Métodos de Otimização
Aplicados à Eng. de Produção**

Aula 1

**Introdução à Otimização Linear
(Parte I)**

Prof. Dr. Aritanan Gruber

Centro de Matemática, Computação e Cognição
Universidade Federal do ABC

Quadrimestre Suplementar 2020

Outline

Notas Iniciais

Introdução à Otimização

Alguns Modelos Lineares

Do Que Se Trata?

Programação Matemática:

- ▶ Programação, neste contexto, significa 'planejamento;'
- ▶ Literalmente, 'modelos matemáticos para planejamento;'
- ▶ Também chamados de **modelos de otimização**.
- ▶ Foco: modelagem, teoria e algoritmos de otimização.

Métodos de Otimização:

- ▶ Um nome mais direto;
- ▶ Métodos, neste contexto, engloba modelagem, teoria e algoritmos.

São largamente usados como sinônimos na literatura.

Notas sobre os Dois Cursos

- ▶ Programação Matemática é um curso de graduação do BCC.
- ▶ Métodos de otimização Aplicados à Eng. de Produção é um curso do mestrado em Eng. de Produção.

Os cursos **não** são iguais (exemplos, profundidade de cobertura dos tópicos e velocidade de exposição variam), mas, claramente, possuem uma parte em comum.

Para estas partes comuns, vamos utilizar os mesmos vídeos e slides. Para as partes específicas, cada curso terá os seus próprios vídeos e slides.

Avaliações e atendimentos são específicos para cada curso.

Notas sobre os Slides

- ▶ Escritos para aulas e não apresentações;
- ▶ Logo, cada slide possui mais texto e mais informação;
- ▶ O tempo de escrita obviamente não ocorre no vídeo (ao contrário das aulas em lousas);
- ▶ De qualquer forma, vou (tentar) controlar o passo para não avançarmos muito rápido e sofrermos com um transbordamento de conteúdo (= cobrir muito mais material do que seria possível em uma aula presencial);
- ▶ Como? Limitando superiormente cada aula a 90min.

Outline

Notas Iniciais

Introdução à Otimização

Alguns Modelos Lineares

Problemas de Otimização

Versão de Minimização

Formulação genérica:

Dados: um funcional *objetivo* f e um conjunto de *pontos viáveis* $S \subseteq \text{dom}(f)$.

Determinar:

- ▶ se $S = \emptyset$, implicando que o problema é *inviável*, ou
- ▶ se $\inf \{f(\mathbf{x}) : \mathbf{x} \in S\} = -\infty$, implicando que o problema é *ilimitado*, ou
- ▶ um $\mathbf{x}^* \in \text{arginf} \{f(\mathbf{x}) : \mathbf{x} \in S\}$, implicando que \mathbf{x}^* é uma *solução ótima* (de valor $f(\mathbf{x}^*) > -\infty$).

Note que as possibilidades acima são mutuamente exclusivas.

Uma instância do problema é dita um *programa de otimização*.

Problemas de Otimização

Versão de Minimização

Estamos interessados em soluções algorítmicas (**modelo uniforme**), que recebem instâncias e devolvem as respostas apropriadas.

Acrescentamos à nossa “lista de desejos:”

- ▶ Algoritmos *eficientes*, cujo consumo de tempo é polinomial no tamanho das instâncias, para determinar as soluções;
- ▶ obtenção de “**certificados**” (sucintos) que atestem a veracidade das respostas fornecidas.

Nota: como $\sup_S\{f\} = -\inf_S\{-f\}$, problemas de maximização também estão contemplados.

Problemas de Otimização

Como introduzido, o problema é tão geral que engloba desde

- ▶ problemas *simples*, com soluções analíticas fechadas (ex. mínimos quadrados em duas variáveis), a
- ▶ problemas que sabemos resolver “*eficientemente*” (ex. emparelhamentos máximos), a
- ▶ problemas que são, potencialmente, “*intratáveis*” (ex. minimização de expressões Booleanas), a
- ▶ problemas *incomputáveis*, para os quais não existem algoritmos (ex. equações diofantinas não lineares).

Vamos evitar o último tipo e nos concentrarmos nos três primeiros.

Problemas de Otimização

Especificação

A função objetivo f e o conjunto de pontos viáveis S podem ser fornecidos

- ▶ explicitamente (*white-box*), via formas algébrica/analítica ou combinatória, ou
- ▶ implicitamente (*black-box*), via oráculos de valor e pertinência.

Vamos trabalhar, primeiro, no regime white-box.

Problemas de Otimização

Especificação

$$\begin{aligned} \min_{x_i} \quad & f(x_1, x_2, \dots, x_n) \\ \text{s.t.} \quad & f_j(x_1, x_2, \dots, x_n) \leq 0 \quad \forall j \in M_1 \\ & f_j(x_1, x_2, \dots, x_n) = 0 \quad \forall j \in M_2 \\ & f_j(x_1, x_2, \dots, x_n) \geq 0 \quad \forall j \in M_3 \\ & x_i \geq 0 \quad \forall i \in N_1 \\ & x_i \leq 0 \quad \forall i \in N_2 \end{aligned}$$

em que

- ▶ f e f_1, f_2, \dots, f_m são funções especificadas algebricamente;
- ▶ M_1, M_2, M_3 são conjuntos finitos e disjuntos de índices;
- ▶ N_1, N_2 são conjuntos finitos e disjuntos de índices;
- ▶ x_1, x_2, \dots, x_n são variáveis de decisão (sobre \mathbb{R} , \mathbb{Q} , ou \mathbb{Z}).

Problemas de Otimização

- ▶ Por não usarmos desigualdades estritas ($<$ e $>$), podemos focar em \min e \max em vez de \inf e \sup ;
- ▶ Vamos nos concentrar em $f, f_j : \mathbb{R}^n \rightarrow \mathbb{R}$, com \mathbb{Q} e \mathbb{Z} no lugar de \mathbb{R} em certas circunstâncias;
- ▶ f é a função objetivo;
- ▶ As desigualdades $f_j \{\leq, =, \geq\} 0$ e $x_i \{\leq, \geq\} 0$ descrevem o conjunto viável S ; são chamadas *restrições*;
- ▶ $x \in \mathbb{R}^n$ é viável se satisfaz as restrições.

Problemas de Otimização

Mínimos locais e globais

Um vetor \mathbf{x} viável é um

- ▶ *mínimo local* se

$$f(\mathbf{x}) \leq f(\mathbf{y}) \quad \text{para todo } \mathbf{y} \in \mathcal{B}(\mathbf{x}, \varepsilon),$$

em que $\mathcal{B}(\mathbf{x}, \varepsilon) := \{\mathbf{y} : \|\mathbf{x} - \mathbf{y}\| \leq \varepsilon\}$ é a “bola” de raio $\varepsilon > 0$ em torno de \mathbf{x} ;



- ▶ *mínimo global* se

$$f(\mathbf{x}) \leq f(\mathbf{y}) \quad \text{para todo } \mathbf{y} \in S.$$

Se \mathbf{x} é mínimo global, então \mathbf{x} é mínimo local; a recíproca, geralmente, não é verdadeira.

Problemas de Otimização


Mínimos locais e globais



Em certas situações (ex., funções convexas sobre conjuntos convexos) todo mínimo local é um mínimo global.

Problemas de Otimização

Panorama



Nota: As noções de convexidade contínua e discreta são diferentes, mas “coincidem.”

Outline

Notas Iniciais

Introdução à Otimização

Alguns Modelos Lineares

Otimização Linear — Exemplo clássico: dieta

Dada a tabela nutricional abaixo, queremos planejar um jantar com os ingredientes de forma que os requisitos de vitaminas e fibras alimentares sejam satisfeitos e o custo da refeição seja o menor possível.

Ingredientes	(a) Cenoura	(b) Repolho	(c) Pepino	Requerido
(1) Vitamina A [mg/kg]	35	0.5	0.5	0.5 mg
(2) Vitamina C [mg/kg]	60	300	10	15 mg
(3) Fibras [g/kg]	30	20	10	4 g
Preço [\$/kg]	0.75	0.5	0.15	—

Sejam $x_a, x_b, x_c \geq 0$ variáveis de decisão em \mathbb{R} tais que x_j representa a quantidade de ingrediente (j) a ser usado na refeição. Um modelo:

$$\begin{aligned} \min_{x_a, x_b, x_c} \quad & 0.75x_a + 0.5x_b + 0.15x_c \\ \text{s.t.} \quad & 35x_a + 0.5x_b + 0.5x_c \geq 0.5 \\ & 60x_a + 300x_b + 10x_c \geq 15 \\ & 30x_a + 20x_b + 10x_c \geq 4 \\ & x_a, x_b, x_c \geq 0 \end{aligned}$$

Otimização Linear — Exemplo clássico: dieta

Uma “solução” para o modelo apresentado fornece as quantidades de cenoura, repolho e pepino que devem ser usadas para uma refeição balanceada ao menor custo possível.

Podemos deixar o problema mais interessante (e realista). Suponha que temos um orçamento W que não pode ser ultrapassado na confecção da refeição.

Estendemos o modelo para:

$$\begin{array}{ll} \min_{x_a, x_b, x_c} & 0.75x_a + 0.5x_b + 0.15x_c \\ \text{s.t.} & 35x_a + 0.5x_b + 0.5x_c \geq 0.5 \\ & 60x_a + 300x_b + 10x_c \geq 15 \\ & 30x_a + 20x_b + 10x_c \geq 4 \\ & 0.75x_a + 0.5x_b + 0.15x_c \leq W \\ & x_a, x_b, x_c \geq 0 \end{array}$$

Otimização Linear — Exemplo clássico: dieta

Os modelos que fornecemos capturam as relações existentes, e que devem ser satisfeitas, em tomadas de decisão. No caso, as quantidades mínimas de ingredientes (pois estamos minimizando o custo da refeição) que devem ser utilizadas e ainda satisfazer os requerimentos nutricionais.

Observe que, neste caso, nossos modelos são concretos: todos os dados estão codificados no modelo (a menos do parâmetro W); são, essencialmente, instâncias.

Não é difícil perceber que podemos generalizá-las a n ingredientes e m compostos (vitaminas, sais minerais, etc.).

Nota: O problema fica computacionalmente mais difícil se as quantidades forem inteiras.

Otimização Linear — Exemplo clássico: dieta

Para isso, suponha que são dados:

- ▶ uma matriz $A \in \mathbb{R}^{m \times n}$, em que a entrada $A_{i,j}$ descreve a quantidade do composto i no ingrediente j , nas unidades escolhidas;
- ▶ um vetor $b \in \mathbb{R}^m$, em que b_i é o requerimento do composto i ;
- ▶ um vetor $c \in \mathbb{R}^n$, em que c_j é o custo por unidade escolhida do ingrediente j .

Seja $x = (x_1, x_2, \dots, x_n)$ um vetor de variáveis reais de decisão; x_j representa a quantidade de ingrediente j a ser usado.

Modelo:

$$\begin{array}{ll} \min_{x} & c^\top x \\ \text{s.t.} & Ax \geq b \\ & x \geq 0 \end{array}$$

Otimização Linear — Exemplo: mochila contínua

Estamos em uma loja que vende produtos alimentícios à granel, como arroz, feijão, aveia, farinha, nozes, castanhas, etc.

Suponha que são vendidos $n \geq 0$ produtos. Cada grama de produto i custa $c_i \geq 0$ e possui, para você, uma utilidade v_i . Você tem um orçamento de W para realizar uma compra.

Problema: selecionar quantidades x_i de cada produto i tal que o custo total não ultrapasse W e a utilidade obtida seja máxima.

Modelo:

$$\begin{aligned} \max_{x_i} \quad & \sum_{i=1}^n v_i x_i \\ \text{s.t.} \quad & \sum_{i=1}^n c_i x_i \leq W \\ & x_i \geq 0 \quad \forall i \in [n] \end{aligned}$$

Otimização Linear — Exemplo: fluxos máximos

Precisamos transportar água de centros produtores ($S \neq \emptyset$) a consumidores ($T \neq \emptyset$). Existem, ainda, centros de distribuição (D) que não fornecem nem absorvem água.

O escoamento da água é feito por tubulações entre certos pares de centros. Para centros $i \neq j$ que estão conectados, a tubulação possui capacidade para escoamento de $u(i, j) \geq 0$ litros (por unidade de tempo; não importante neste problema).

Podemos supor que não há perdas (vazamentos) na rede e que cada tubulação é usada em um único sentido.

Objetivo: escoar a maior quantidade possível de água dos centros produtores aos consumidores, respeitando as capacidades das tubulações.

Otimização Linear — Exemplo: fluxos máximos

Claramente, este é um problema de fluxos em digrafos: o famoso problema do **fluxo máximo**.

Um digrafo $G = (S \uplus T \uplus D, E)$ descreve uma rede de abastecimento de água: um arco $(i, j) \in E$ se existe uma tubulação do centro i ao centro j , com $i \neq j$.

Sem perda de generalidade, suponha que não há arcos (i, s) para $s \in S$ e (t, j) para $t \in T$. Podemos ter, simultaneamente, arcos (i, j) e (j, i) para $i, j \in D$, com $i \neq j$.

Um vetor $\mathbf{u} \in \mathbb{R}^E$ descreve as capacidades dos arcos (tubulações); $\mathbf{x} \in \mathbb{R}_{\geq 0}^E$ é um vetor de variáveis de decisão – uma para cada arco – que tomam valores reais não negativos: fluxo que será escoado por cada arco.

Otimização Linear — Exemplo: fluxos máximos


$$\begin{aligned} \max_{\mathbf{x}} \quad & \sum \{x(s, j) : s \in S, (s, j) \in E\} \\ \text{s.t.} \quad & \sum_{(i, j) \in E} x(i, j) - \sum_{(j, i) \in E} x(j, i) = 0 \quad \forall i \in D \quad (\bullet) \\ & 0 \leq x(i, j) \leq u(i, j) \quad \forall (i, j) \in E \end{aligned}$$

- ▶ As restrições (\bullet) garantem a conservação de fluxo nos centros de distribuição: a quantidade de fluxo que entra é igual à que sai (lei de Kirchhoff);
- ▶ O problema é trivial se G for bipartido ($D = \emptyset$);
- ▶ Obtemos o mesmo resultado com

$$\sum \{x(i, t) : t \in T, (i, t) \in E\}$$

como função objetivo (prove!).

Otimização Linear — Exemplo: fluxos máximos



(extraída de Cormen-Leiserson-Rivest-Stein)

$$S = \{s\}, T = \{t\}, D = \{v_1, v_2, v_3, v_4\}.$$

Otimização Linear — Exemplo: fluxos máximos

$$\max \quad x(s, v_1) + x(s, v_2)$$

$$\text{s.t.} \quad x(v_1, v_2) + x(v_1, v_3) - x(s, v_1) - x(v_2, v_1) = 0$$

$$x(v_2, v_1) + x(v_2, v_4) - x(s, v_2) - x(v_1, v_2) - x(v_3, v_2) = 0$$

$$x(v_3, t) + x(v_3, v_2) - x(v_1, v_3) - x(v_4, v_3) = 0$$

$$x(v_4, t) + x(v_4, v_3) - x(v_2, v_4) = 0$$

$$0 \leq x(s, v_1) \leq 16$$

$$0 \leq x(s, v_2) \leq 13$$

$$0 \leq x(v_1, v_2) \leq 10$$

$$0 \leq x(v_1, v_3) \leq 12$$

$$0 \leq x(v_2, v_1) \leq 4$$

$$0 \leq x(v_2, v_4) \leq 14$$

$$0 \leq x(v_3, t) \leq 20$$

$$0 \leq x(v_3, v_2) \leq 9$$

$$0 \leq x(v_4, t) \leq 4$$

$$0 \leq x(v_4, v_3) \leq 7$$

Otimização Linear — Ex: fluxo de custo mínimo

Queremos, agora, transportar água de centros produtores ($S \neq \emptyset$) a consumidores ($T \neq \emptyset$). Cada centro $i \in S$ fornece $b(i) > 0$ litros de água e cada centro $i \in T$ absorve $b(i) < 0$ litros.

Existem, ainda, centros de distribuição (D) que não fornecem nem absorvem água: $b(i) = 0$ para todo $i \in D$.

O escoamento da água é feito por tubulações entre certos pares de centros. Podemos supor que não há perdas (vazamentos) na rede e que cada tubulação é usada em um único sentido.

Para centros $i \neq j$ que estão conectados, a tubulação possui capacidade para escoamento de $u(i, j) \geq 0$ litros por unidade de tempo, a um custo $c(i, j) \geq 0$.

Otimização Linear — Ex: fluxo de custo mínimo

Objetivo: escoar água dos centros produtores aos consumidores, respeitando as capacidades das tubulações e incorrendo no menor custo possível.

Este é outro problema de fluxo sobre digrafos: **fluxo de custo mínimo**.

Um digrafo $G = (S \uplus T \uplus D, E)$ descreve uma rede de abastecimento de água: um arco $(i, j) \in E$ se existe uma tubulação do centro i ao centro j , com $i \neq j$.

Sem perda de generalidade, suponha que não há arcos (i, s) para $s \in S$ e (t, j) para $t \in T$. Podemos ter, simultaneamente, arcos (i, j) e (j, i) para $i, j \in D$, com $i \neq j$.

Vetores $\mathbf{u} \in \mathbb{R}^E$ e $\mathbf{c} \in \mathbb{R}^E$ descrevem as capacidades e custos de uso dos arcos (tubulações); $\mathbf{x} \in \mathbb{R}_{\geq 0}^E$ é um vetor de variáveis de decisão: fluxo que será escoado por cada arco.

Otimização Linear — Ex: fluxo de custo mínimo

$$\begin{aligned} \min_{\mathbf{x}} \quad & \sum_{(i,j) \in E} c(i,j)x(i,j) \\ \text{s.t.} \quad & \sum_{(i,j) \in E} x(i,j) - \sum_{(j,i) \in E} x(j,i) = b_i \quad \forall i \in S \uplus T \uplus D \quad (\star) \\ & 0 \leq x(i,j) \leq u(i,j) \quad \forall (i,j) \in E \end{aligned}$$

- ▶ As restrições (\star) garantem que as demandas são satisfeitas;
- ▶ Se $\sum_{s \in S} b_s \neq -\sum_{t \in T} b_t$, o problema é inviável;
- ▶ Mais do que isso, caso exista $\emptyset \neq R \subset S \uplus T \uplus D$ tal que

$$\sum_{\substack{r \in R \\ (i,r) \in E}} u(i,r) < -\sum_{r \in R} b_r,$$


o problema é inviável.

Otimização Linear — Ex: regressão ℓ_1 em 2 vars.

Suponha que temos uma coleção de pontos no plano \mathbb{R}^2 :


$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n).$$

Como na figura abaixo, extraída de Matoušek-Gärtner (pg. 19).



Otimização Linear — Ex: regressão ℓ_1 em 2 vars.

Queremos determinar uma reta $y = ax + b$ que “melhor aproxime” os pontos dados.



Várias possibilidades de solução. Escolhemos a busca pela reta que minimiza a norma ℓ_1 :

$$\min_{a,b} \sum_{i=1}^n |ax_i + b - y_i|.$$

Otimização Linear — Ex: regressão ℓ_1 em 2 vars.

Problema: a função objetivo não é linear.

Mas é linear por partes! Podemos assim, *reformular* o modelo em uma versão linear.

Temos que $|ax_i + b - y_i| \geq 0$ implica em $ax_i + b - y_i \geq 0$ ou $-(ax_i + b - y_i) \geq 0$. Logo, introduzindo uma variável auxiliar e_i (erro no ponto i) tal que

$$\begin{aligned}e_i &\geq ax_i + b - y_i \\e_i &\geq -(ax_i + b - y_i)\end{aligned}$$

obtemos que

$$e_i \geq \max\{ax_i + b - y_i, -(ax_i + b - y_i)\} = |ax_i + b - y_i|.$$

Otimização Linear — Ex: regressão ℓ_1 em 2 vars.

Temos, então, a reformulação linear:

$$\begin{aligned} \min_{a, b, e_i} \quad & \sum_{i=1}^n e_i \\ \text{s.t.} \quad & e_i \geq ax_i + b - y_i \quad \forall i \in [n] \\ & e_i \geq -(ax_i + b - y_i) \quad \forall i \in [n] \end{aligned}$$

Nota: A regressão ℓ_2 (norma euclidiana), conhecida como **mínimos quadrados** consiste em uma função objetivo quadrática

$$\min_{a, b} \sum_{i=1}^n (ax_i + b - y_i)^2,$$


e necessita diferentes técnicas para resolução.

Otimização Linear — Ex: separação em \mathbb{R}^2

Suponha que temos duas coleções de pontos no plano \mathbb{R}^2 , uma de pontos brancos e outra de pontos pretos:


$$(r_1, s_1), (r_2, s_2), \dots, (r_m, s_m) \quad \text{e} \quad (w_1, z_1), (w_2, z_2), \dots, (w_n, z_n).$$

Como na figura abaixo, extraída de Matoušek-Gärtner (pg. 21).



Otimização Linear — Ex: separação em \mathbb{R}^2

Queremos determinar uma reta $y = ax + b$ que “separe” os pontos dados. De preferência, deixando uma “margem” de segurança.



Atente para o fato de que o problema pode não ter solução.

Otimização Linear — Ex: separação em \mathbb{R}^2

Um ponto (p_i, q_i) está de um “lado” da reta se $q_i > ap_i + b$ e do “outro” se $q_i < ap_i + b$.

Introduzimos uma variável auxiliar δ para representar a margem e “fechar o espaço” entre as desigualdades estritas.

$$\begin{array}{ll} \max_{a, b, \delta} & \delta \\ \text{s.t.} & s_i \geq ar_i + b + \delta \quad \forall i \in [m] \\ & z_j \leq aw_j + b - \delta \quad \forall j \in [n] \end{array}$$

Por Que Estudar Otimização Linear?

- ▶ De certa forma, é uma extensão natural de álgebra linear, envolvendo desigualdades e máximos/mínimos;
- ▶ Não obstante, várias ideias interessantes foram e ainda são desenvolvidas na área; muitas delas, foram generalizadas para outros domínios e casos não lineares;
- ▶ **Dualidade** é uma ferramenta poderosa na prova de teoremas e desenvolvimento de algoritmos, tanto exatos quanto aproximados;
- ▶ Serve como ferramenta para resolução de problemas maiores mais complexos;
- ▶ Possui inúmeras aplicações teóricas e práticas, direta ou indiretamente, em uma miríade de campos:
 - ▶ Aprendizado de máquina
 - ▶ Biologia e neurociência
 - ▶ Economia e finanças
 - ▶ Engenharias
 - ▶ Física
 - ▶ Matemática
 - ▶ Química
 - ▶ Teoria da computação