

- 1 Qual a qualidade do limitante dual obtido ao resolver o dual lagrangiano ?
- 2 Como se pode resolver o dual lagrangiano ?

- Qualidade do limitante:

• e supor que $X = \{x^1, x^2, \dots, x^T\}$, com T finito;

• $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_m) \in \mathbb{R}^m$;

• para todo $x \in X$, $c^T x + \sum_{i=1}^m \lambda_i (a_i^T x - b_i) \leq c^T x$;

• $\lambda^* = \arg \max_{\lambda \in \mathbb{R}^m} \{c^T x + \sum_{i=1}^m \lambda_i (a_i^T x - b_i)\}$;

• $\lambda^* = \arg \max_{\lambda \in \mathbb{R}^m} \{c^T x + \sum_{i=1}^m \lambda_i (a_i^T x - b_i)\}$;

• $\lambda^* = \arg \max_{\lambda \in \mathbb{R}^m} \{c^T x + \sum_{i=1}^m \lambda_i (a_i^T x - b_i)\}$;

- Resolvendo o dual Lagrangiano:

- alternativa 1: usar um algoritmo de otimização por subgradientes;
- alternativa 2: usar PL e um algoritmo de planos de corte.

Definição 5: $g : \mathbb{R}^n \rightarrow \mathbb{R}$ é uma **função convexa** se, para todos pontos x e y de \mathbb{R}^n e $\lambda \in [0, 1]$,


$$g(\lambda x + (1 - \lambda)y) \leq \lambda g(x) + (1 - \lambda)g(y)$$

● **Proposição 6:** $z(u) = \max\{cx + u(d - Dx)\}$ é convexa.

Prova:
$$\begin{cases} w = \lambda u + (1 - \lambda)v \\ z(w) = c\bar{x} + w(d - D\bar{x}) \quad (\bar{x} \in X) \end{cases}$$

$$\begin{aligned} c\bar{x} + u(d - D\bar{x}) &\leq z(u) && [\lambda] \\ c\bar{x} + v(d - D\bar{x}) &\leq z(v) && [1 - \lambda] \end{aligned}$$
$$\lambda z(u) + (1 - \lambda)z(v) \geq z(w) \quad \square.$$

• **Proposição 7:** uma função $g : \mathbb{R}^n \rightarrow \mathbb{R}$ é convexa se e somente se, para todo $x^* \in \mathbb{R}^n$ existe $s \in \mathbb{R}^n$ tal que $g(x^*) + s(x - x^*) \leq g(x)$ para todo $x \in \mathbb{R}^n$.




- Estando em x^* , que direção deve ser seguida para minimizar $g(x)$?

Usando a Proposição 7, se x é tal que $g(x) < g(x^*)$, então necessariamente $s(x - x^*) < 0$. Ou seja, a partir de x^* movendo-se (de uma quantidade adequada) na **direção oposta** àquela de s , $g(\cdot)$ irá **diminuir de valor** !


- **Como achar s ?** Se g é diferenciável em x^* , fazer $s = -\nabla g(x^*)$ (**gradiente de g em x^***).

curvas de nível de $g(x)$



- E se $g(\cdot)$ é convexa mas não for diferenciável ?

$$g(x_1, x_2) = \max\{x_1, -x_1 + 2x_2, -x_1 - 2x_2\}$$




- $s^1 = (-1, 2)$
- $s^2 = (-1, -2)$
- o hiperplano suporte não é único em $(-2, 0)$!
- as direções $-s^1$ e $-s^2$ não são de descida !

Pelo menos sabemos que a solução ótima satisfaz

$$s(x - x^*) < 0 !$$

- Portanto, é possível sair de x^* e dar um passo pequeno na direção $-s$ de modo a me aproximar mais de um ponto ótimo \hat{x} .



Definição 8: se $g : \mathbb{R}^n \rightarrow \mathbb{R}$ é uma função convexa, então s é um **subgradiente** de g em x^* se e somente se

$$s(x - x^*) \leq g(x) - g(x^*), \forall x \in \mathbb{R}^n.$$

O **subdiferencial** ($\delta g(x^*)$) de g em x^* é o conjunto de todos os subgradientes de g neste ponto.

Proposição 9: Se g é convexa e $0 \in \delta g(x^*)$ então $g(x^*) = \min\{g(x) : x \in \mathbb{R}^n\}$, ou seja, x^* é **ótimo**.

- **Em teoria:** se queremos minimizar uma função convexa g , basta começar de um ponto qualquer e iterativamente ir se deslocando a pequenos passos na direção oposta àquela de um subgradiente de g naquele ponto até que 0 pertença ao subdiferencial do ponto corrente.

- Como calcular um subgradiente de $z(u) = \max\{cx + u(d - Dx) : x \in X\}$ no ponto u ?

- **Proposição 10:** Seja $\bar{x} \in X$ tal que $z(u) = c\bar{x} + u(d - D\bar{x})$. Então, $(d - D\bar{x})$ é um subgradiente de $z(u)$ em u .

Prova:

$$z(v) \geq cx + v(d - Dx), \forall x \in X, \text{ logo}$$
$$z(v) \geq c\bar{x} + v(d - D\bar{x}).$$

Mas, $c\bar{x} = z(u) - u(d - D\bar{x})$, portanto,

$$z(v) \geq z(u) + (v - u)(d - D\bar{x}). \quad \square$$

- O **algoritmo de subgradiente** para resolver o problema dual lagrangiano:

Inicialização: $k = 0$, escolher u^0 .

Iteração k :

- $u = u^k$;
- Resolver $IP(u^k)$. Seja $x(u^k)$ uma solução ótima.
- **Passo na direção oposta ao subgradiente:**
 $u^{k+1} \leftarrow \max\{u^k - \mu_k(d - Dx(u^k)), 0\}$
- $k \leftarrow k + 1$;
- Se o **critério de parada** não está satisfeito, **execute** mais uma iteração.

- μ é chamado de **tamanho do passo**.
- Qual o tamanho do passo que deve ser dado ?
(problemas de convergência)

Teorema 11:

- (a) Se $\sum_k \mu_k \rightarrow \infty$ e $\mu_k \rightarrow 0$ então $z(u^k) \rightarrow w_{LD}$.
- (b) Se $\mu_k = \mu_0 \rho^k$, com $\rho < 1$ e μ_0 e ρ são suficientemente grandes, então $z(u^k) \rightarrow w_{LD}$.
- (c) Se $\bar{w} \geq w_{LD}$ e $\mu_k = \epsilon \frac{z(u^k) - \bar{w}}{\|d - D_x(u^k)\|^2}$ com $0 < \epsilon < 2$, então $z(u^k) \rightarrow \bar{w}$, ou o algoritmo encontra u^k com $\bar{w} \geq z(u^k) \geq w_{LD}$ para algum k finito.

Comentários:

(a) converge lentamente !

(b) dificuldade em escolher μ_0 e ρ “altos” .

Na prática só faz decréscimo geométrico do passo após um número constante de iterações.

(c) dificuldade em encontrar um limitante superior \bar{w} .

Na prática, usa-se uma estimativa para o limitante superior, mas isto não garante convergência !

Esta estimativa muitas vezes é substituída pelo melhor limitante primal conhecido ... (ver discussão no livro texto)

É o método mais usado !

Método do Subgradiente aplicado ao TSP simétrico

- restrições dualizadas: grau dos nós (= 2).
- Direção do passo:

$$u_i^{k+1} = u_i^k + \mu_k \left(2 - \sum_{e \in \delta(i)} x_e(u^k) \right).$$

- tamanho do passo (regra (c)):

$$\mu_k = \epsilon_k (\underline{w} - z(u^k)) / \sum_{i \in V} (2 - \sum_{e \in \delta(i)} x_e(u^k))^2.$$

- **Nota:** o problema dual neste caso é de maximização e os multiplicadores são irrestritos em sinal.


- **Instância:** grafo completo com 5 nós e custos dados por

$$c = \begin{bmatrix} - & 30 & 26 & 50 & 40 \\ & - & 24 & 40 & 50 \\ & & - & 24 & 26 \\ & & & - & 30 \\ & & & & - \end{bmatrix}$$

- **Uma solução heurística:** *tour* $\{1, 2, 3, 4, 5, 1\}$ de custo 148.
- Método do subgradiente com a regra (c) e $\epsilon_k = 1 \dots$

- **Iteração 1:** supondo $u^1 = \{0, 0, 0, 0, 0\}$, a matriz de **custos lagrangianos** coincide com a matriz original.

$$\tilde{c} = \begin{bmatrix} - & 30 & 26 & 50 & 40 \\ & - & 24 & 40 & 50 \\ & & - & 24 & 26 \\ & & & - & 30 \\ & & & & - \end{bmatrix}$$



- 1-árvore ótima com custo $z(u^1) = 130$;
- **subgradiente em u^1 :**

$$(2 - \sum_{e \in \delta(i)} x_e(u^1))_{i=1, \dots, 5} = (0, 0, -2, 1, 1).$$


- **atualização dos multiplicadores:**

$$u^2 = u^1 + 1 \cdot [(148 - 130)/6](0, 0, -2, 1, 1)$$

$$u^2 = (0, 0, -6, 3, 3)$$

- **Iteração 2:** para $u^2 = (0, 0, -6, 3, 3)$, a matriz de custos lagrangianos é dada por:

$$\tilde{c} = \begin{bmatrix} - & 30 & 32 & 47 & 37 \\ & - & 30 & 37 & 47 \\ & & - & 27 & 29 \\ & & & - & 24 \\ & & & & - \end{bmatrix}$$



- 1-árvore ótima com custo $z(u^2) = 143 + 2 \sum_i u_i^2 = 143$;
- subgradiente em u^2 :

$$(2 - \sum_{e \in \delta(i)} x_e(u^2))_{i=1, \dots, 5} = (0, 0, -1, 0, 1).$$


- atualização dos multiplicadores:

$$u^3 = u^2 + 1 \cdot [(148 - 143)/2](0, 0, -1, 0, 1)$$

$$u^3 = (0, 0, -8.5, 3, 5.5)$$

- **Iteração 3:** para $u^3 = (0, 0, -8.5, 3, 5.5)$, a matriz de **custos lagrangianos** é dada por:

$$\tilde{c} = \begin{bmatrix} - & 30 & 34.5 & 47 & 34.5 \\ & - & 32.5 & 37 & 44.5 \\ & & - & 29.5 & 29 \\ & & & - & 21.5 \\ & & & & - \end{bmatrix}$$



- 1-árvore ótima com custo $z(u^2) = 147.5$;
- **solução ótima:** os custos inteiros e já se conhece um limitante superior de 148 !

• A relaxação lagrangiana pode ser usada dentro de um **algoritmo exato** do tipo *branch-and-bound* para produzir limitantes duais.