

MÉTODO DUAL-SIMPLEX PARA PROBLEMAS COM
CRITÉRIO LINEAR POR PARTES

ANILTON SALLES GARCIA

ORIENTADOR

HERMANO M.F. TAVARES

Dissertação apresentada no Instituto de Matemática Estatística e Ciência da Computação, UNICAMP, como requisito parcial para obtenção do título de Mestre em Matemática Aplicada.

JULHO 1978

SUMÁRIO

É dada a posição de um problema de Programação Linear por Partes e a notação utilizada.. Apresentamos o desenvolvimento de um método do tipo Dual-Simplex para problemas com critério Linear por Partes, o algoritmo correspondente, um diagrama de bloco simplificado e exemplos de Aplicação, além de nossa visão sobre o método Primal-Simplex para Programação Linear por Partes..

INDICE

CAPÍTULO 1 - INTRODUÇÃO	1
1.1 - Posição do Problema	1
1.2 - Sequência do Trabalho	2
1.3 - Notação Utilizada	3
CAPÍTULO 2 - MÉTODO DUAL SIMPLEX PARA PROBLEMAS COM CRITÉRIO LINEAR POR PARTES	5
2.1 - Introdução	5
2.2 - Apresentação do Problema	5
2.3 - Estratégia de Resolução do Problema	12
2.4 - <i>Estudo Detalhado do 3º CASO</i>	22
- Como se Preparar para uma nova Iteração	33
- Algoritmo	35
CAPÍTULO 3 - EXEMPLOS DE APLICAÇÃO E INTERPRETAÇÃO GEOMÉTRICA	36
3.1 - Introdução	36
3.2 - Diagrama de Bloco Simplificado do Algoritmo	36
3.3 - Exemplos de Aplicação	38
3.4 - Interpretação Geométrica	46
CAPÍTULO 4 - PROGRAMAÇÃO LINEAR POR PARTES	49
4.1 - Introdução	49
4.2 - Apresentação do Problema de Programação Linear por Partes	49
4.3 - Método de Resolução do Problema (P)	51
4.4 - Descrição em Detalhe de uma Iteração	57
4.4.1 - Estudo Detalhado da <u>Situação a</u>	59

CAPÍTULO I

INTRODUÇÃO

1.1 - POSIÇÃO DO PROBLEMA

Na sua visão mais simples, a Programação Linear por Partes pode ser encarada como uma generalização da Programação Linear onde o critério (função objetivo) é Linear por Partes e as restrições são Lineares como num problema de Programação Linear.

Um problema de Programação Linear (PL) pode ser apresentado sob a forma:

$$(PL) \left\{ \begin{array}{l} \text{Minimizar } Z = \underline{c} \underline{x} \\ \text{sujeito a: } \left\{ \begin{array}{l} A \underline{x} = \underline{b} \\ - \underline{x} \geq 0 \end{array} \right. \end{array} \right.$$

com $A(m,n)$, $\underline{c}(1,n)$, $\underline{x}(n,1)$ e $\underline{b}(m,1)$.

Enquanto que um problema de Programação Linear por Partes (PLP), apresentado por YODINE [2], por nós abordado, pode ser colocado sob a forma:

$$(PLP) \left\{ \begin{array}{l} \text{Minimizar } F(\underline{x}) = \sum_{j=1}^n f_j(x_j) \\ \text{sujeito a: } \left\{ \begin{array}{l} A \underline{x} = \underline{b} \\ \underline{\alpha} \leq \underline{x} \leq \underline{\beta} \end{array} \right. \end{array} \right.$$

onde cada função $f_j(x_j)$ é convexa Linear por Partes.

Neste trabalho tratamos do desenvolvimento de um método do tipo Dual-Simplex para problemas com critério Linear por Partes, que é uma extensão do método clássico Dual-Simplex para Programação Linear, LUENBERGER [3].

O método desenvolvido apresenta sua base matemática fundamentada na Teoria da Dualidade de Lagrange, LASDON [1].

Embora, neste processo, o número de Soluções Básicas seja, geralmente, muito maior do que num problema de Programação Linear, o método desenvolvido apresenta eficiência idêntica à do Simplex, SAKAROVITCH [4].

O método desenvolvido nos parece de grande aplicação na resolução de problemas que apresentam um grande número de variáveis e com estrutura decomponível. Como exemplo de uma possível aplicação poderíamos citar a resolução de alguns problemas de Programação Matemática onde o critério (Linear por Partes) e as restrições (Lineares) se apresentam de forma aditiva separável, problema que J.F.R. FERNANDES desenvolve atualmente como extensão do trabalho publicado por J.F.R. FERNANDES e G. AUTHIE [5], a nível de Tese de Doutorado.

Este método é finito, tendo sua convergência assegurada em um número finito de iterações, além de não possuir intervalo ("gap") de dualidade; determina-se assim os ótimos do Dual e do Primal.

Vale lembrar também que devido o conjunto de soluções ser compacto (fechado e limitado), o problema (PLP) ou apresentará uma solução finita (solução tipo α) ou será infactível, estando afastada a hipótese de termos infinitos ótimos (solução tipo β).

1.2 - SEQUÊNCIA DO TRABALHO

No capítulo 2, apresentamos o desenvolvimento matemático que nos levaram à resolução do (PLP) baseando-nos no método clássico Dual-Simplex, bem como mostramos que o método proposto não apresenta intervalo ("gap") de dualidade e que sua convergência é assegurada. Apresentamos também o Algoritmo para a resolução do problema proposto. Acreditamos que os resultados deste capítulo são originais.

No capítulo 3, apresentamos os aspectos computacionais, fornecendo um diagrama de bloco simplificado do método desenvolvido e um exemplo de aplicação onde foram testadas diferentes possibilidades de evolução do método: Solução Tipo α para o Primal, So-

lução não Factível, Redundância e ainda uma Solução Múltipla para o problema Primal, o que implica em uma degenerescência para o problema Dual. Todos os resultados obtidos foram compatíveis com o método desenvolvido.

No capítulo 4, apresentamos a nossa visão sobre o Método Primal-Simplex para problemas com critério Linear por Partes, apresentado por YODINE [2], usando notação própria. A apresentação é concisa, simples, original, orientada para o uso computacional e guarda grande analogia com o capítulo 2.

1.3 - NOTAÇÃO UTILIZADA

As matrizes serão representadas por letras latinas maiúsculas e os vetores, por minúsculas grifadas.

$A(m,n)$: matriz de m linhas e n colunas

$\underline{b}(m,1)$: vetor coluna de m elementos: b_1, b_2, \dots, b_m

$\underline{c}(1,n)$: vetor linha de n elementos: c^1, c^2, \dots, c^n

A_i^j : denota-nos o elemento de A situado na j -ésima coluna e na i -ésima linha.

A^j : sendo $A(m,n)$, A^j indica-nos a j -ésima coluna de A , ou seja, um vetor coluna de componentes $A_1^j, A_2^j, \dots, A_m^j$

A_i : denota-nos a i -ésima linha de A

I : conjunto de índices, $I \subset \{1,2,3,\dots,n\}$, que é dito ser uma base; $x_i, i \in I$, é denominada "variável básica". Trabalharemos sempre com I sendo um conjunto ordenado de índices.

J : conjunto de índices, $J = \{1,2,\dots,n\} - \{I\}$, denominado conjunto das variáveis não básicas.

\underline{x}_I : indica-nos o vetor coluna de m elementos $x_i, i \in I$, formado pelas variáveis básicas

\underline{x}_J : indica-nos o vetor coluna de $(n - m)$ elementos $x_j, j \in J$, formado pelas variáveis não básicas.

$d_{k,j}$: valor crítico do j -ésimo argumento da função $f_j(x_j)$, com $k = 0,1,\dots,l_{j+1}$

$\underline{d}_{k,J}$: vetor dos valores críticos correspondentes ao vetor \underline{x}_J .

Consideraremos também aqui os conceitos usualmente empregados na resolução de Sistemas lineares como:

- Sistema Linear e Programa Linear
- Incompatibilidade e Redundância
- Base
- Forma Básica
- Operações elementares com linhas
- Pivoteamento e Matriz de Pivoteamento

bem como suas propriedades.

CAPÍTULO 2

MÉTODO DUAL SIMPLEX PARA PROBLEMAS COM CRITÉRIO LINEAR POR PARTES

2.1 - INTRODUÇÃO

Neste capítulo apresentaremos o desenvolvimento matemático de um método do tipo dual-simplex para resolução de modelos lineares com critério (função objetivo) linear por partes, que é o objetivo principal deste trabalho.

Apresentaremos também alguns conceitos específicos para o método estudado, com a finalidade de facilitar seu entendimento.

O método dual-simplex para resolução de problemas com critério linear por partes pode ser visto como uma extensão do método dual-simplex para resolução de problemas com critério linear.

O método estudado tem sua base matemática fundamentada na Teoria de Lagrange tendo eficiência idêntica à do simplex, embora com um número maior de soluções básicas.

Provaremos a convergência do método em um número finito de passos e a não existência de "gap" de dualidade.

Apresentaremos detalhadamente todas as situações possíveis quanto às soluções, e o desenvolvimento matemático de uma das situações, apresentando a analogia com as demais.

2.2 - APRESENTAÇÃO DO PROBLEMA


Seja o Problema:

$$\text{Minimizar } F(\underline{x}) = \sum_{j=1}^n f_j(x_j) \quad (2.1)$$

$$\text{sujeito a: } \begin{cases} A \underline{x} = \underline{b} & (2.2) \\ \underline{\alpha} \leq \underline{x} \leq \underline{\beta} & (2.3) \end{cases}$$

com $A(m, n)$, $\underline{x}(n, 1)$, $\underline{b}(m, 1)$, sendo A uma matriz de "rank" m e

$f_j(x_j)$ convexa, linear por partes.



$$f_j(x_j) \triangleq \begin{cases} C_0^j x_j & \alpha_j \leq x_j \leq d_{1,j} \\ C_1^j x_j + g_{1j} & d_{1,j} \leq x_j \leq d_{2,j} \\ \vdots & \vdots \\ C_{l_j}^j x_j + g_{l_j j} & d_{l_j,j} \leq x_j \leq \beta_j \end{cases} \quad (2.4)$$

com $l_j = \text{número de intervalos} - 1$

$$g_{kj} \triangleq f_j(d_{k,j}) - C_k^j d_{k,j} \quad (2.5)$$

onde $C_k^j = C_0^j + \sum_{i=1}^k \sigma_i^j$ com $\sigma_i^j > 0$ (2.6)

e $S = \{ \underline{x} / A \underline{x} = \underline{b} \text{ e } \underline{\alpha} \leq \underline{x} \leq \underline{\beta} \}$ (2.7)

Apresentaremos aqui as seguintes definições:

- INCLINAÇÃO: chamaremos de inclinação aos valores C_k^j , $k=0,1,\dots,l_j$, correspondentes a cada trecho linear da função $f_j(x_j)$.
- VALORES CRÍTICOS: valores correspondentes aos pontos de mudança de inclinação da função $f_j(x_j)$. Serão os $d_{k,j}$, $k=0,\dots,l_{j+1}$. As inclinações \bar{a} direita e \bar{a} esquerda de cada valor crítico, C_{k-1}^j e C_k^j , serão ditas Inclinações Adjacentes ao valor crítico.
- INTERVALO: conjunto de valores que uma variável pode assumir entre dois valores críticos adjacentes.

Por dualização em relação a (2.2) obtemos o seguinte Lagrangeano:

$$L(\underline{x}, \underline{p}) = F(\underline{x}) + \underline{p}(\underline{b} - A \underline{x}) \quad (2.8)$$

$$L(\underline{x}, \underline{p}) = \underline{p} \underline{b} + \sum_{j=1}^n (f_j(x_j) - \underline{p} A^j x_j) \quad (2.9)$$

onde A^j é uma coluna da matriz A e $\underline{p}(1 \times m)$ é o vetor das variáveis duais (parâmetros de Lagrange).

A função dual é definida por:

$$\Phi(\underline{p}) = \text{Min}_{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}} L(\underline{x}, \underline{p}) = \underline{p} \underline{b} + \text{Min}_{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}} \left[\sum_{j=1}^n (f_j(x_j) - \underline{p} A^j x_j) \right] \quad (2.10)$$

cujo valor é dado por:

$$\Phi(\underline{p}) = \underline{p} \underline{b} + \sum_{j=1}^n (f_j(d_{k,j}) - \underline{p} A^j d_{k,j}) \quad (2.11)$$

com

$$c_{k-1}^j \leq p \leq c_k^j \quad \Delta \quad z^j \leq c_k^j \quad (2.12)$$

sendo z^j chamado de INCLINAÇÃO DE REFERÊNCIA.

Neste trabalho faremos uso de notações particulares para diferentes situações:

- $\underline{x} = \underline{x}^0$ será o(s) valor(es) assumido(s) por \underline{x} no processo de otimização descrito por (2.10) e (2.11), ou seja,

$$\Phi(p) = \underset{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}}{\text{Min}} L(\underline{x}, p) = L(\underline{x}^0, p) \quad (2.13)$$

Evidentemente $\underline{\alpha} \leq \underline{x}^0 \leq \underline{\beta}$

- $\underline{x} = \underline{x}^+$ denotará um valor básico assumido por \underline{x} ao resolver o sistema $A \underline{x} = \underline{b}$; necessariamente não satisfaz $\underline{\alpha} \leq \underline{x} \leq \underline{\beta}$. Chamando:

I = Conjunto de índices das variáveis básicas

J = Conjunto de índices das variáveis não básicas

A^I = Matriz formada pelas colunas $A^i, i \in I$

A^J = Matriz formada pelas colunas $A^j, j \in J$

$$\underline{x} = \begin{bmatrix} \underline{x}_I \\ \underline{x}_J \end{bmatrix} \quad \text{e} \quad A = \begin{bmatrix} A^I & A^J \end{bmatrix}$$

\underline{x}_I = Vetor formado pelas variáveis básicas

\underline{x}_J = Vetor formado pelas variáveis não básicas

e fixando $\underline{x}_J^+ = \underline{d}_{k,J}$ (2.14)

resulta: $A^I \underline{x}_I + A^J \underline{x}_J = \underline{b}$


$$\underline{x}_I = \underline{x}_I^+ = (A^I)^{-1} (\underline{b} - A^J \underline{d}_{k,J})$$

$$\underline{x}_I^+ = \bar{b} - \bar{A}^J \underline{d}_{k,J} \quad (2.15)$$

Para $\underline{p} \in \mathbb{R}^m$ e $\underline{y} \in \mathbb{R}^m$, fixados, exploraremos a função $\Delta\phi(t) = \phi(\underline{p} + t \underline{y}) - \phi(\underline{p})$; isto corresponde a estudar um corte da função $\phi(\underline{p})$, num processo de Busca Unidirecional.

É fácil verificar que:

- a) $\phi(\underline{p})$ é côncava, linear por partes e definida $\forall \underline{p} \in \mathbb{R}^m$; portanto $\Delta\phi(t)$ é côncava e linear por partes em t .



Aqui levaremos em conta as seguintes definições:

- TAXA DE CRESCIMENTO: será o valor da inclinação de cada trecho linear da função $\Delta\phi(t)$.
- PONTO DE QUEBRA: ponto onde ocorre mudança de inclinação (taxa de crescimento) da função $\Delta\phi(t)$. A cada ponto de quebra corresponde um valor para t denominado VALOR DE QUEBRA.

- b) $\forall \underline{p} \in \mathbb{R}^m$ e $\forall \underline{x} \in S$ tem-se: $\phi(\underline{p}) \leq F(\underline{x})$ pois:

$$\phi(\underline{p}) = \min_{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}} L(\underline{x}, \underline{p}) = L(\underline{x}^0, \underline{p}) \leq L(\underline{x}, \underline{p}), \forall \underline{x}, \underline{\alpha} \leq \underline{x} \leq \underline{\beta} \quad (2.16)$$

$$\phi(\underline{p}) \leq F(\underline{x}) + \underline{p}(\underline{b} - A \underline{x}), \forall \underline{x}, \underline{\alpha} \leq \underline{x} \leq \underline{\beta} \quad (2.17)$$

Em particular, se $\underline{x} \in S$ temos: $\underline{b} - A \underline{x} = 0$

$$e \quad \phi(\underline{p}) \leq F(\underline{x}) \quad (2.18)$$

c) Em especial se $\underline{x} = \underline{x}^0$, que otimiza $L(\underline{x}, \underline{p})$ na obtenção de $\phi(\underline{p})$, também satisfizer $A \underline{x} = \underline{b}$, teremos:

$$\phi(\underline{p}) = F(\underline{x}^0) \leq F(\underline{x}) \quad , \quad \forall \underline{x} \in S$$

$$e \quad \underline{x}^0 \in S$$

ou seja, \underline{x}^0 é ótimo do problema original.

d) No processo de otimização, se tivermos:

$$c_{k-1}^j < z^j < c_k^j \quad , \quad \text{SITUAÇÃO I, temos então fixado } x_j = x_j^0 = d_{k,j}$$

Se tivermos $z^j = c_k^j$, SITUAÇÃO II, teremos então que $d_{k,j} \leq x_j = x_j^0 \leq d_{k+1,j}$, com liberdade de variar dentro deste intervalo.

O nosso objetivo será portanto, obter um valor $\underline{x} = \underline{x}^0$ que também satisfaça $A \underline{x} = \underline{b}$; obtenhamos m "SITUAÇÃO II" definindo uma base I e forçando, através da escolha de \underline{p} , a igualdade:

$$\underline{p} A^I = \underline{z}^I = \underline{c}_k^I \quad (2.19)$$

Ao escolhermos, para cada componente x_i^0 , $i \in I$, a inclinação c_k^i que figura em (2.19), selecionamos conseqüentemente o intervalo

$$d_{k,i} \leq x_i^0 \leq d_{k+1,i} \quad , \quad i \in I$$

As demais $n-m$ componentes do vetor \underline{x}^0 cairão na SITUAÇÃO I e serão fixadas num valor crítico:

$$x_j^0 = d_{k,j} \quad , \quad j \in J$$

Por outro lado, a esta base I corresponde um valor \underline{x}^+ de finido por (2.14) e (2.15).

Mostraremos que $L(\underline{x}^0, \underline{p}) = \phi(\underline{p})$ é uma aproximação de $F(\underline{x}^+)$ do tipo Linearização Externa; deste ponto de vista, \underline{x}^+ seria uma Solução Básica Otimista.

$$L(\underline{x}^0, \underline{p}) = F(\underline{x}^0) + \underline{p}(\underline{b} - A \underline{x}^0)$$

$$L(\underline{x}^0, \underline{p}) = \sum_{j=1}^n f_j(x_j) + \underline{p}(\underline{b} - A^J \underline{x}_J^0) - \underline{p} A^I \underline{x}_I^0 \quad (2.20)$$

Mas, $\underline{x}_j^0 = \underline{x}_j^+ = \underline{d}_{k,J}$


e $A^I \underline{x}_I^+ = \underline{b} - A^J \underline{x}_J^+ = \underline{b} - A^J \underline{x}_J^0$

Logo, a expressão (2.20) pode ser escrita sob a forma:

$$L(\underline{x}^0, \underline{p}) = \sum_{j \in J} f_j(x_j^0) + \sum_{i \in I} f_i(x_i^0) + \underline{p} A^I \underline{x}_I^+ - \underline{p} A^I \underline{x}_I^0$$

$$L(\underline{x}^0, \underline{p}) = \sum_{j \in J} f_j(x_j^0) + \sum_{i \in I} f_i(x_i^0) + \underline{z}^I (\underline{x}_I^+ - \underline{x}_I^0)$$

$$L(\underline{x}^0, \underline{p}) = \sum_{j \in J} f_j(x_j^0) + \sum_{i \in I} \left[f_i(x_i^0) + z^i (x_i^+ - x_i^0) \right] \quad (2.21)$$



sendo $f_{i,a}(x_i^+)$ o valor aproximado da função $f_i(x_i^+)$.

Daí, $L(\underline{x}^0, \underline{p}) = F_a(\underline{x}^+)$ e, evidentemente, para todo $\underline{x} \in S$ temos que:

$$F_a(\underline{x}^+) \leq F(\underline{x}) \quad (2.22)$$

Então, \underline{x}^+ é uma Solução Básica Otimista.

2.3 - ESTRATÉGIA DE RESOLUÇÃO DO PROBLEMA

Trataremos aqui da resolução do problema (P) apresentada no parágrafo anterior e cuja função dual é apresentada em (2.10)

$$(P) \left\{ \begin{array}{l} \text{Minimizar } F(\underline{x}) = \sum_{j=1}^n f_j(x_j) \\ \text{s.a. : } \left\{ \begin{array}{l} A \underline{x} = \underline{b} \\ \underline{\alpha} \leq \underline{x} \leq \underline{\beta} \end{array} \right\} \quad \underline{x} \in S \end{array} \right.$$

O problema dual de (P) é:

$$(D) \left\{ \begin{array}{l} \text{Maximizar } \Phi(\underline{p}) \\ \underline{p} \in R^m \end{array} \right. \quad (2.23)$$

Nosso objetivo é desenvolver um método de resolução para o problema (D) - dual-simplex - mostrando também que não há, neste caso, "gap" de dualidade: então (P) também ficará resolvido.

- Escolhe-se uma base I e, para todo $i \in I$, o intervalo de definição da variável x_i e, conseqüentemente, a Inclinação de Referência.

$$\text{Inclinação de Referência: } Z^i = C_k^i$$

Intervalo de Definição: $d_{k,i} \leq x_i \leq d_{k+1,i}$

- Calcula-se $\underline{p} = \underline{p}^*$ de modo que:


$$\underline{p}^* A^I = \underline{Z}^I = \underline{C}_k^I$$

$$\underline{p}^* = \underline{C}_k^I (A^I)^{-1} \quad (2.24)$$


Para melhor entendimento da representação gráfica, escrevamos (2.10) da seguinte forma:

$$\Phi(\underline{p}^*) = \text{Min}_{\underline{\alpha} \leq x \leq \underline{\beta}} \left\{ \underline{p}^* \underline{b} + \sum_{i \in I} [f_i(x_i) - Z^{*i} x_i] + \sum_{j \in J} [f_j(x_j) - Z^{*j} x_j] \right\} \quad (2.25)$$

Para cada variável básica $i \in I$ foi escolhida uma Inclinação de Referência $Z^{*i} = C_k^i$, tendo sido determinado o intervalo correspondente, $d_{k,i} \leq x_i \leq d_{k+1,i}$, como mostra a figura abaixo:



No caso das variáveis não básicas, $j \in J$, o valor da Inclinação de Referência Z^{*j} obtido, $C_{k-1}^j < Z^{*j} < C_k^j$, leva a variável não básica a um valor crítico (no caso do problema não degenerado). Assim $x_j = d_{k,j}$, $\forall j \in J$.



Note que neste processo sempre teremos "m" variáveis livres, podendo assumir valores dentro de um determinado intervalo, com as quais tentaremos satisfazer $A \underline{x} = \underline{b}$.

Assim, a expressão (2.25) passa a ser:

$$\phi(\underline{p}^*) = \underline{p}^* \underline{b} + \sum_{i \in I} g_{k,i} + \sum_{j \in J} \left[f_j(d_{k,j}) - Z^{*j} d_{k,j} \right] \quad (2.26)$$

O objetivo do problema (D) é maximizar $\phi(\underline{p})$. Assim, temos que verificar se $\phi(\underline{p}^*)$ já é o máximo de $\phi(\underline{p})$. Para isso devemos verificar em um entorno de \underline{p}^* , o comportamento da função $\phi(\underline{p})$.

Isto corresponde a efetuarmos Buscas Unidirecionais do tipo:

$$\underline{p} = \underline{p}^* + t \underline{v}.$$

No nosso processo vamos impor uma variação de \underline{p} que provoque a modificação de apenas uma componente do vetor \underline{z}^I .

$$\underline{z}^I - \underline{c}_k^I = t [0, \dots, 1, 0, \dots] = t \underline{i}_r \quad (2.27)$$

A variação de \underline{p} é:

$$\underline{p} = \underline{p}^* + t \underline{i}_r (A^I)^{-1} \triangleq \underline{p}^* + t \underline{y}_r \quad (2.28)$$

Com isso temos a alteração de apenas uma componente do vetor \underline{z}^I (a r -ésima componente, que pode ser escolhida como aquela que nos proporciona a maior TAXA DE CRESCIMENTO). As demais componentes permanecem inalteradas.

Para um valor de t não nulo e suficientemente pequeno (pequena mudança na Inclinação de Referência), podemos verificar que no processo de otimização que nos leva do $L(\underline{x}, \underline{p})$ para a função dual $\Phi(\underline{p})$, ocorre que:

a) Todas as variáveis x_j^0 , $j \in J$, continuarão com sua Inclinação de Referência se enquadrando na SITUAÇÃO I (partindo da hipótese do problema não ser dual degenerado)

b) Todas as variáveis x_i^0 , $i \in I$ e $i \neq r$, continuarão com suas Inclinações de Referência se enquadrando na SITUAÇÃO II, obtida por construção

c) A variável x_r^0 que se enquadrava na SITUAÇÃO II passa a se enquadrar na SITUAÇÃO I:

$$x_r^0(t) = \begin{cases} d_{k,r} & \text{se } t < 0 \\ d_{k+1,r} & \text{se } t > 0 \end{cases}$$

Temos então que fazer uma avaliação do valor da função $\Phi(\underline{p})$ para o incremento considerado, verificando se há um crescimento da função.

Assim:

$$L(\underline{x}, \underline{p}^* + t \underline{v}_r) = (\underline{p}^* + t \underline{v}_r) \underline{b} + \sum_{j=1}^n \left\{ f_j(x_j) - (\underline{p}^* + t \underline{v}_r) A^j x_j \right\} \quad (2.29)$$

Fazendo: $I' \triangleq I - \{r\}$ e $J' \triangleq J \cup \{r\}$, temos:

$$\phi(\underline{p}^* + t \underline{v}_r) = \min_{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}} L(\underline{x}, \underline{p}^* + t \underline{v}_r)$$

$$\begin{aligned} \phi(\underline{p}^* + t \underline{v}_r) = \min_{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}} & \left[(\underline{p}^* + t \underline{v}_r) \underline{b} + \sum_{i \in I'} \left\{ f_i(x_i) - (\underline{p}^* + t \underline{v}_r) A^i x_i \right\} + \right. \\ & \left. + \sum_{j \in J'} \left\{ f_j(x_j) - (\underline{p}^* + t \underline{v}_r) A^j x_j \right\} \right] \quad (2.30) \end{aligned}$$

e para $i \in I'$, temos que $\underline{v}_r A^i = 0$

Note que o valor da r -ésima componente que estava definido em um intervalo, agora se define em um valor crítico.

Dai:


$$\begin{aligned} \phi(\underline{p}^* + t \underline{v}_r) = & (\underline{p}^* + t \underline{v}_r) \underline{b} + \sum_{i \in I'} g_{k,i} + \sum_{j \in J} \left\{ f_j(d_{k,j}) - (\underline{p}^* + t \underline{v}_r) A^j d_{k,j} \right\} + \\ & + \min_{\alpha_r \leq x_r \leq \beta_r} \left\{ f_r(x_r) - \underline{p}^* A^r x_r - t \underline{v}_r A^r x_r \right\}, \end{aligned}$$

Sendo $\underline{v}_r A^r = 1$.

$$\phi(\underline{p}^* + t\underline{v}_r) = (\underline{p}^* + t\underline{v}_r)\underline{b} + \sum_{i \in I} g_{k,i} + \sum_{j \in J} \left\{ f_j(d_{k,j}) - (\underline{p}^* + t\underline{v}_r) A^j d_{k,j} \right\} +$$

$$+ g_{k,r} - \begin{cases} t d_{k,r} & \text{se } t < 0 \\ t d_{k+1,r} & \text{se } t > 0 \end{cases},$$

onde o sinal de t é dado segundo a figura abaixo:



$$\phi(\underline{p}^* + t \underline{v}_r) = \underline{p}^* \underline{b} + \sum_{i \in I} g_{k,i} + \sum_{j \in J} \left\{ f_j(d_{k,j}) - z^{*j} d_{k,j} \right\} + t \underline{v}_r \underline{b} -$$

$$- \sum_{j \in J} t \underline{v}_r A^j d_{k,j} - \begin{cases} t d_{k,r} & \text{se } t < 0 \\ t d_{k+1,r} & \text{se } t > 0 \end{cases}$$

$$\phi(\underline{p}^* + t \underline{v}_r) = \phi(\underline{p}^*) + t \underline{v}_r \underline{b} - t \underline{v}_r \sum_{j \in J} A^j d_{k,j} - \begin{cases} t d_{k,r} & \text{se } t < 0 \\ t d_{k+1,r} & \text{se } t > 0 \end{cases}$$

$$\phi(\underline{p}^* + t \underline{v}_r) = \phi(\underline{p}^*) + t(\bar{b}_r - \bar{A}_r^J \underline{d}_{k,J}) - \begin{cases} t d_{k,r} & \text{se } t < 0 \\ t d_{k+1,r} & \text{se } t > 0 \end{cases}$$

De (2.15): $x_r^+ = \bar{b}_r - \bar{A}_r^J \underline{d}_{k,J}$, obtemos:


$$\phi(\underline{p}^* + t \underline{v}_r) = \phi(\underline{p}^*) + \begin{cases} t (x_r^+ - d_{k,r}) & \text{se } t < 0 \\ t (x_r^+ - d_{k+1,r}) & \text{se } t > 0 \end{cases} \quad (2.31)$$

que também pode ser escrita como:


$$\phi(\underline{p}^* + t \underline{v}_r) = \phi(\underline{p}^*) + t [x_r^+ - x_r^0(t)] \quad (2.32)$$

Com relação ao valor de x_r^+ , podemos constatar a ocorrência de 3 casos, como mostraremos a seguir:


1º CASO: $x_r^+ < d_{k,r} < d_{k+1,r}$




O gráfico da função $\phi(\underline{p}^* + t \underline{v}_r)$ será:




2º CASO: $d_{k,r} < x_r^+ < d_{k+1,r}$




O gráfico da função $\phi(\underline{p}^* + t \underline{v}_r)$ será:




3º CASO: $x_r^+ > d_{k+1,r} > d_{k,r}$



O gráfico da função $\phi(\underline{p}^* + t \underline{v}_r)$ será:



É evidente que não é possível a existência de um 4º CASO em que a função $\phi(\underline{p}^* + t \underline{v}_r)$ cresça para ambos os lados.





Quando o valor obtido para x_r^+ nos indicar que caímos no 2º CASO, não é necessário procedermos a uma Busca Unidirecional do tipo $\underline{p} = \underline{p}^* + t \underline{v}_r$, uma vez que a função $\phi(\underline{p}^* + t \underline{v}_r)$ decresce para todo valor de t não nulo.

2.4 - ESTUDO DETALHADO DO 3º CASO

Faremos aqui um estudo detalhado para o 3º CASO apresentado no parágrafo anterior onde, $x_r^+ > d_{k+1,r} > d_{k,r}$, e apresentaremos as equações correspondentes ao 1º CASO, onde $x_r^+ < d_{k,r} < d_{k+1,r}$, cujo desenvolvimento é análogo ao que será apresentado para o 3º CASO.

ESTUDO DO 3º CASO



Em relação a este 3º CASO, um aumento (pequeno) de t proporciona um aumento linear de $\phi(\underline{p})$; simultaneamente variarão as Inclinações de Referência das variáveis $j \in J'$:

$$Z^r = \underline{p} A^r = (\underline{p}^* + t \underline{v}_r) A^r = \underline{p}^* A^r + t \underline{v}_r A^r = Z^{*r} + t \quad (2.33)$$

$$Z^s = \underline{p} A^s = (\underline{p}^* + t \underline{v}_r) A^s = \underline{p}^* A^s + t \underline{v}_r A^s = Z^{*s} + t \tilde{A}_r^s, \quad \text{se } J \quad (2.34)$$

A Inclinação de Referência da variável x_r gira positivamente; da variável x_s , $s \in J$, positivamente se $\tilde{A}_r^s > 0$, negativamente se $\tilde{A}_r^s < 0$ e não gira se $\tilde{A}_r^s = 0$.

Daí, podemos concluir que:

- a) Z^r tende para C_{k+1}^r
- b) se $\tilde{A}_r^s > 0$, temos que Z^s tende para C_k^s
- c) se $\tilde{A}_r^s = 0$, temos que Z^s é insensível ao aumento de t
- d) se $\tilde{A}_r^s < 0$, temos que Z^s tende para C_{k-1}^s

Temos, portanto, $(n - m + 1)$ possíveis limites de t a serem alcançados; a cada um deles corresponderia, em princípio, uma transição SITUAÇÃO I \rightarrow SITUAÇÃO II.

A expressão:

$$\Delta\phi(t) = \phi(\underline{p}^* + t \underline{v}_r) - \phi(\underline{p}^*) = t(x_r^+ - x_r^0),$$

deixaria de valer logo que o primeiro deles fosse alcançado, pois mudaria o valor de x_r^+ ou de x_r^0 .

A limitação do crescimento do t pode ser dada pela variável r ou por uma variável não básica.

Devemos tomar: $t = \min\{t_r, t_j \ \forall j \in J\}$

Vamos analisar separadamente os dois casos:

A) A limitação do crescimento de t é dada pela variável r .

$$\begin{aligned}z^r &= c_{k+1}^r \\(\underline{p}^* + t_r \underline{v}_r) A^r &= c_{k+1}^r \\ \underline{p}^* A^r + t_r \underline{v}_r A^r &= c_{k+1}^r \\c_k^r + t_r &= c_{k+1}^r \\t_r &= c_{k+1}^r - c_k^r \\t_r &= \sigma_{k+1}^r\end{aligned}\tag{2.35}$$

B) A limitação do crescimento de t é dada pela variável j , $j \in J$.

Temos aqui dois casos a analisar:

B.1) $\tilde{A}_r^j > 0$

B.2) $\tilde{A}_r^j < 0$

B.1) $\tilde{A}_r^j > 0 \rightarrow z^j = c_k^j$

$$z^{*j} + t_j \tilde{A}_r^j = c_k^j$$

$$t_j = \frac{c_k^j - z^{*j}}{\tilde{A}_r^j}\tag{2.36}$$

$$B.2) \quad \bar{A}_r^j < 0 \rightarrow z^j = c_{k-1}^j$$



$$z^{*j} + t_j \bar{A}_r^j = c_{k-1}^j$$

$$t_j = \frac{c_{k-1}^j - z^{*j}}{\bar{A}_r^j} \quad (2.37)$$

Dado o crescimento de $\phi(\underline{p})$, devemos verificar o que acontecerá após um Ponto de Quebra na função $\phi(\underline{p})$ se continuarmos aumentando o valor de t .

O que vai ocorrer após o Ponto de Quebra, dependerá do tipo de Ponto de Quebra Verificado.

1º TIPO: O Valor de Quebra é dado pela variável r .



Então:

$\exists t_1 > 0$ tal que:

$$t_1 = \sigma_{k+1}^r$$

e
$$c_{k-1}^j < z^{*j} + t_1 \tilde{A}_r^j < c_k^j, \quad \forall j \in J$$

Devemos testar o comportamento da função para um pequeno acréscimo de t_1 .

Então, devemos comparar $\phi(\underline{p}^* + t_1 \underline{v}_r)$ com $\phi(\underline{p}^* + (t_1 + \epsilon) \underline{v}_r)$, com $\epsilon > 0$ e suficientemente pequeno.

Assim:

$$L(\underline{x}, \underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = (\underline{p}^* + (t_1 + \epsilon) \underline{v}_r) \underline{b} + \sum_{j=1}^n \left[f_j(x_j) - (\underline{p}^* + (t_1 + \epsilon) \underline{v}_r) A^j x_j \right]$$

$$\begin{aligned} L(\underline{x}, \underline{p}^* + (t_1 + \epsilon) \underline{v}_r) &= (\underline{p}^* + t_1 \underline{v}_r) \underline{b} + \sum_{j=1}^n \left[f_j(x_j) - (\underline{p}^* + t_1 \underline{v}_r) A^j x_j \right] + \\ &+ \epsilon \underline{v}_r \underline{b} - \sum_{j=1}^n \epsilon \underline{v}_r A^j x_j \end{aligned}$$

$$\begin{aligned} L(\underline{x}, \underline{p}^* + (t_1 + \epsilon) \underline{v}_r) &= L(\underline{x}, \underline{p}^* + t_1 \underline{v}_r) + \epsilon \underline{v}_r \underline{b} - \sum_{i \in I} \epsilon \underline{v}_r A^i x_i - \\ &- \sum_{j \in J} \epsilon \underline{v}_r A^j x_j \end{aligned}$$

$$L(\underline{x}, \underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = L(\underline{x}, \underline{p}^* + t_1 \underline{v}_r) + \epsilon \bar{b}_r - \epsilon x_r - \epsilon \tilde{A}_r^J x_J$$

$$L(\underline{x}, \underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = L(\underline{x}, \underline{p}^* + t_1 \underline{v}_r) + \epsilon \left[(\bar{b}_r - \tilde{A}_r^J x_J) - x_r \right]$$

(2.38)

A função dual será:

$$\phi(\underline{p}^* + (t_1 + \varepsilon) \underline{v}_r) = \underset{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}}{\text{Min}} L(\underline{x}, \underline{p}^* + (t_1 + \varepsilon) \underline{v}_r)$$

$$\phi(\underline{p}^* + (t_1 + \varepsilon) \underline{v}_r) = \underset{\underline{\alpha} \leq \underline{x} \leq \underline{\beta}}{\text{Min}} L(\underline{x}, \underline{p}^* + t_1 \underline{v}_r) + \underset{x_r}{\text{Min}} \varepsilon \left[(\bar{b}_r - \bar{A}_r^J x_J) - x_r \right]$$

$$\phi(\underline{p}^* + (t_1 + \varepsilon) \underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \varepsilon \left[(\bar{b}_r - \bar{A}_r^J d_{k,J}) - d_{k+2,r} \right]$$

$$\phi(\underline{p}^* + (t_1 + \varepsilon) \underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \varepsilon (x_r^+ - d_{k+2,r}) \quad (2.39)$$

Temos assim determinada, a nova Taxa de crescimento da função $\phi(\underline{p})$.

$$\text{Chamando: } \begin{cases} \text{TCN} = \text{Taxa de crescimento nova} \\ \text{TCA} = \text{Taxa de crescimento antiga} \end{cases}$$

$$\text{TCN} = x_r^+ - d_{k+2,r}$$

$$\text{TCA} = x_r^+ - d_{k+1,r}$$

$$\text{Daí: } \text{TCN} = \text{TCA} - (d_{k+2,r} - d_{k+1,r}) \quad (2.40)$$

- Caso esta TCN ainda seja positiva, isso indica que podemos aumentar o valor de t até o próximo limitante que está garantido um aumento da função $\phi(\underline{p})$.



- Se esta TCN for não positiva, devemos parar com a Busca Unidirecional, pois não haverá mais crescimento no valor da função $\phi(\underline{p})$.

No caso de uma quebra do 1º TIPO, o valor de x_r^+ permanece inalterado e a diferença entre x_r^+ e o Intervalo de Definição da variável $x_r^0(t)$ diminui porque a nova diferença para o novo Intervalo de Definição será $(x_r^+ - d_{k+2,r})$, que é menor que a diferença em relação ao Intervalo de Definição antigo $(x_r^+ - d_{k+1,r})$. Com isso, x_r^+ está mais próximo do Intervalo de Definição de $x_r^0(t)$, ou seja, está caminhando para a FACTIBILIDADE.

2º TIPO: O Valor de Quebra é dado pela variável s , $s \in J$.

Como vimos anteriormente, quando a limitação do crescimento do t é dada por uma variável s , $s \in J$, temos que levar em consideração o sinal de \bar{A}_r^s .

Tomemos então o caso $\bar{A}_r^s > 0$



Então:

$\exists t_1 > 0$ tal que:

$$t_1 < \sigma_{k+1}^r$$

$$t_1 = \frac{C_k^s - Z^{*s}}{\bar{A}_r^s}$$

e $C_{k-1}^j < Z^{*j} + t_1 \bar{A}_r^j < C_k^j$, $\forall j$, $j \in J - \{s\}$

Novamente:

$$L(\underline{x}, \underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = L(\underline{x}, \underline{p}^* + t_1 \underline{v}_r) + \epsilon \left[(\bar{b}_r - \bar{A}_r^J \underline{x}_J) - x_r \right]$$

e, usando a definição de $\phi(\underline{p})$, temos:

$$\phi(\underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \epsilon \left[(\bar{b}_r - \bar{A}_r^{J-\{s\}} \underline{d}_{k,J-\{s\}} - \bar{A}_r^s d_{k+1,s}) - d_{k+1,r} \right]$$

$$\phi(\underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \epsilon \left[(\bar{b}_r - \bar{A}_r^{J-\{s\}} \underline{d}_{k,J-\{s\}} - \bar{A}_r^s d_{k+1,s} + \bar{A}_r^s d_{k,s} - \bar{A}_r^s d_{k,s}) - d_{k+1,r} \right]$$

$$\phi(\underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \epsilon \left[(\bar{b}_r - \bar{A}_r^J \underline{d}_{k,J}) - \bar{A}_r^s (d_{k+1,s} - d_{k,s}) - d_{k+1,r} \right]$$

$$\phi(\underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \epsilon \left[(x_r^* - d_{k+1,r}) - \bar{A}_r^s (d_{k+1,s} - d_{k,s}) \right]$$

(2.41)

Da expressão (2.41) concluímos que:

$$TCN = TCA - \tilde{A}_r^S (d_{k+1,s} - d_{k,s}) \quad (2.42)$$

Caso a TCN seja positiva, indica que podemos crescer t até o próximo limitante que a função $\phi(\underline{p})$ continuará crescendo.

Caso contrário devemos parar com a Busca Unidirecional, pois não haverá mais crescimento no valor da função $\phi(\underline{p})$.

Podemos dar para este caso, a seguinte interpretação:

Seja:

$$\Delta x_r^+ = \tilde{A}_r^S (d_{k+1,s} - d_{k,s}) \quad (2.43)$$


$$e \quad \Delta\phi(\epsilon) = \phi(\underline{p}^* + (t_1 + \epsilon)\underline{v}_r) - \phi(\underline{p}^* + t_1 \underline{v}_r) \quad (2.44)$$


Então:

$$\Delta\phi(\epsilon) = \epsilon \left[(x_r^+ - \Delta x_r^+) - d_{k+1,r} \right] \quad (2.45)$$

Neste caso, x_r^0 passa a estar definido em um valor crítico. Entretanto x_r^+ se aproxima deste valor crítico, uma vez que foi subtraído de Δx_r^+ , $\Delta x_r^+ > 0$. Assim, há uma tendência de x_r^+ caminhar para um intervalo em que x_r^0 venha a se definir.

Ainda no 2º TIPO, vamos abordar agora o caso em que $\tilde{A}_r^S < 0$





Para este caso verificamos que:

$\exists t_1 > 0$ tal que:

$$t_1 < \sigma_{k+1}^r$$

$$t_1 = \frac{C_{k-1}^s - Z^{*s}}{\bar{A}_r^s}$$

e $C_{k-1}^j < Z^{*j} + t_1 \bar{A}_r^j < C_k^j \quad \forall j, j \in J - \{s\}$

Novamente:

$$L(\underline{x}, \underline{p}^* + (t_1 + \epsilon) \underline{v}_r) = L(\underline{x}, \underline{p}^* + t_1 \underline{v}_r) + \epsilon \left[(\bar{b}_r - \bar{A}_r^J \underline{x}_J) - x_r \right]$$

e, usando a definição da função $\phi(\underline{p})$, temos:

$$\phi(\underline{p}^* + (t_1 + \varepsilon)\underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \varepsilon \left[(\tilde{b}_r - \tilde{A}_r^{J-\{s\}} \underline{d}_{k,J-\{s\}} - \tilde{A}_r^s \underline{d}_{k-1,s}) - \underline{d}_{k+1,r} \right]$$

$$\phi(\underline{p}^* + (t_1 + \varepsilon)\underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \varepsilon \left[(\tilde{b}_r - \tilde{A}_r^{J-\{s\}} \underline{d}_{k,J-\{s\}} - \tilde{A}_r^s \underline{d}_{k-1,s} + \tilde{A}_r^s \underline{d}_{k,s} - \tilde{A}_r^s \underline{d}_{k,s}) - \underline{d}_{k+1,r} \right]$$

$$\phi(\underline{p}^* + (t_1 + \varepsilon)\underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \varepsilon \left[(\tilde{b}_r - \tilde{A}_r^J \underline{d}_{k,J}) - \tilde{A}_r^s (\underline{d}_{k-1,s} - \underline{d}_{k,s}) - \underline{d}_{k+1,r} \right]$$

$$\phi(\underline{p}^* + (t_1 + \varepsilon)\underline{v}_r) = \phi(\underline{p}^* + t_1 \underline{v}_r) + \varepsilon \left[(x_r^+ - \underline{d}_{k+1,r}) - \tilde{A}_r^s (\underline{d}_{k-1,s} - \underline{d}_{k,s}) \right] \quad (2.45)$$

Da expressão (2.45) concluímos que:

$$TCN = TCA - \tilde{A}_r^s (\underline{d}_{k-1,s} - \underline{d}_{k,s}) \quad (2.46)$$

Se TCN for positiva, indica que a função $\phi(\underline{p})$ cresce nessa direção e, portanto, crescemos o t até o seu próximo limitante.

Caso contrário devemos parar com a Busca Unidirecional, pois não haverá mais crescimento do valor da função $\phi(\underline{p})$.

Desenvolvimento análogo poderia ser apresentado para o 1º CASO citado anteriormente onde, os valores atribuídos a t se

riam negativos.

As expressões obtidas são idênticas às do 3º CASO, a menos de variações nos valores críticos correspondentes. Também aqui são válidas as mesmas observações quanto às TAXAS DE CRESCIMENTO da função $\Phi(p)$, lembrando porém que elas são, em princípio, NEGATIVAS, conforme a figura ilustrativa do 1º CASO.

- COMO SE PREPARAR PARA UMA NOVA ITERAÇÃO

Tudo o que foi apresentado, é justificado para uma iteração. Entretanto, quando não é possível garantir o crescimento da função $\Phi(p)$, devemos passar para outra iteração, com a finalidade de buscar esse aumento.

Ao final de uma iteração, existem dois casos possíveis para a preparação de uma nova iteração:

1º CASO: Houve mudança de solução básica sem haver mudança de base.

Neste caso, devemos recalculamos o valor das variáveis básicas através da expressão (2.15), recomeçando todo o processo iterativo.

2º CASO: Houve mudança de base.

Neste caso, supondo que a variável não básica que entrou na base seja a variável s , seja s , a variável s terá sua Inclinação de Referência igualada a uma das Inclinações da função $f_s(x_s)$, podendo com isso assumir valores dentro do seu Intervalo de Definição.

A variável r , $r \in I$, que tornou-se não-básica terá sua Inclinação de Referência situada entre duas Inclinações da função $f_r(x_r)$, adjacentes a um valor crítico, tendo assim a variável x_r um valor determinado. Faz-se então um pivoteamento no elemento \bar{A}_r^s que é não nulo, recalcula-se o valor da nova solução básica e reinicia-se o processo iterativo.

TEOREMA:

A partir do instante em que não for possível aumentar o

valor da função $\phi(\underline{p})$ de acordo com este processo, temos garantida a existência de uma SOLUÇÃO BÁSICA FACTÍVEL e ÓTIMA.

DEMONSTRAÇÃO:

No processo, caminhamos de \underline{p} em \underline{p} de modo que sempre temos garantido que m componentes x_j , $j \in I$, tenham suas Inclinações de Referência coincidentes com uma Inclinação da função $f_j(x_j)$. Calcula-se \underline{x}_I^+ .

Se $\phi(\underline{p})$ não pode mais crescer nas m explorações unidirecionais do tipo:

$$\underline{p} = \underline{p}^* + t \underline{v}_r, \quad r \in I$$

é porque temos para cada variável básica o 2º CASO, referente a fórmula (2.32).

$$\phi(\underline{p}^* + t \underline{v}_r) = \phi(\underline{p}^*) + t(x_r^+ - x_r^0(t)), \quad r \in I$$

donde

$$d_{k,r} < x_r^+ < d_{k+1,r}, \quad r \in I$$

e consequentemente:

$$\underline{x} = \underline{x}^0 = \underline{x}^+ = \begin{bmatrix} \underline{x}_I^+ \\ \underline{x}_J^+ \end{bmatrix} = \begin{bmatrix} \tilde{b} - \tilde{A}^J d_{k,J} \\ d_{k,J} \end{bmatrix}$$

é solução básica, factível e, de acordo com o item c da página 10, também ótima.

Em outras palavras:

$$\text{Max}_{\underline{p} \in R^m} \phi(\underline{p}) = \text{Min}_{\underline{x} \in S} F(\underline{x})$$

isto é, o par de problemas duais (P) e (D) não apresentam "gap" de dualidade.

ALGORITMO

PASSO 1: Escolhe-se uma base I inicial.

PASSO 2: Determinam-se os trechos de localização das variáveis x_i , $i \in I$. Determinação do valor de \underline{c}_k^I .

PASSO 3: Calculam-se os valores de $Z^j, \forall j$, de modo que $\underline{z}^I = \underline{c}_k^I$.

PASSO 4: Determinam-se os valores das variáveis $x_j, j \in J$.

PASSO 5: Calcula-se o valor das variáveis básicas \underline{x}_I^+ .

PASSO 6: Calculam-se as Taxas de Crescimento referentes à base I e escolhe-se como variável básica candidata a sofrer alterações a de maior TC.

Se $TC \max \leq 0 \rightarrow$ A solução obtida é ótima

Se $TC \max > 0$ continue.

PASSO 7: Identifica-se para onde tende a girar a Inclinação de Referência da variável básica escolhida.

PASSO 8: Calculam-se os valores limitantes de t para a variável básica escolhida e todas as não básicas.

PASSO 9: Escolhe-se o menor limitante de t .

Se t_{\min} é ilimitado \rightarrow o Problema Primal não possui solução factível.

Caso contrário continue.

PASSO 10: Calcula-se a nova TC para a variável correspondente ao t_{\min} .

Se para esta TC $\Delta\phi(t)$ ainda aumenta, redefine-se o valor da variável, calcula-se o seu novo limitante de t e vã para o PASSO 9.

Caso contrário identifica-se a variável escolhida:

Se for básica vã para o PASSO 5

Se for não básica faça mudança de base, pivoteia no elemento correspondente e vã para o PASSO 5.


CAPÍTULO 3


EXEMPLOS DE APLICAÇÃO E INTERPRETAÇÃO GEOMÉTRICA

3.1 - INTRODUÇÃO

Neste capítulo apresentaremos um diagrama de bloco simplificado para o algoritmo desenvolvido no capítulo 2, um exemplo de aplicação do método com todos os testes realizados quanto às soluções e uma interpretação geométrica para o método estudado.

3.2 - DIAGRAMA DE BLOCO SIMPLIFICADO DO ALGORÍTMO





Os passos mencionados no diagrama de bloco acima se referem ao algoritmo apresentado no capítulo anterior.

3.3 - EXEMPLO DE APLICAÇÃO

O exemplo padrão que abordamos foi inspirado num problema encontrado no capítulo 7 de YODINE [2], resolvido através do método Primal-Simplex. Tal exemplo apresenta certas particularidades conforme mostraremos no desenvolvimento deste parágrafo.

Seja o PLP:

$$\text{Minimizar } F(\underline{x}) = \sum_{j=1}^8 f_j(x_j)$$

sujeito a:

$$\begin{pmatrix} 1 & -2 & 3 & -1 & 5 & -3 & 1 & -1 \\ 3 & 1 & -1 & 2 & 2 & -2 & -3 & 4 \\ -2 & 1 & 1 & 0 & 1 & 1 & 0 & -2 \\ 5 & -4 & 0 & 3 & -2 & 0 & -1 & 0 \end{pmatrix} \underline{x} \leq \begin{pmatrix} 10 \\ 8 \\ 7 \\ 5 \end{pmatrix} \quad (3.1)$$

$$\underline{x}^T = (x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8)$$

$$0 \leq x_1 \leq 4, \quad 0 \leq x_2 \leq 5, \quad 0 \leq x_3 \leq 6, \quad 0 \leq x_4 \leq 50$$

$$0 \leq x_5 \leq 2, \quad 0 \leq x_6 \leq 200, \quad 0 \leq x_7 \leq 7, \quad 0 \leq x_8 \leq 5$$

onde as funções $f_j(x_j)$ são definidas como:

$$f_1(x_1) = \begin{cases} -8x_1 & 0 \leq x_1 \leq 1 \\ -5x_1 - 3 & 1 \leq x_1 \leq 2 \\ -4x_1 - 5 & 2 \leq x_1 \leq 3 \\ -2x_1 - 11 & 3 \leq x_1 \leq 4 \end{cases} \quad (3.2)$$

$$f_2(x_2) = \begin{cases} -9 x_2 & 0 \leq x_2 \leq 1 \\ -7 x_2 - 2 & 1 \leq x_2 \leq 2 \\ -6 x_2 - 4 & 2 \leq x_2 \leq 3 \\ -5 x_2 - 7 & 3 \leq x_2 \leq 4 \\ -3 x_2 - 15 & 4 \leq x_2 \leq 5 \end{cases} \quad (3.3)$$

$$f_3(x_3) = \begin{cases} -8 x_3 & 0 \leq x_3 \leq 2 \\ -4 x_3 - 8 & 2 \leq x_3 \leq 5 \\ -x_3 - 23 & 5 \leq x_3 \leq 6 \end{cases} \quad (3.4)$$

$$f_4(x_4) = -6 x_4 \quad 0 \leq x_4 \leq 50 \quad (3.5)$$

$$f_5(x_5) = \begin{cases} -8 x_5 & 0 \leq x_5 \leq 1 \\ -5 x_5 - 3 & 1 \leq x_5 \leq 2 \end{cases} \quad (3.6)$$

$$f_6(x_6) = \begin{cases} -9 x_6 & 0 \leq x_6 \leq 2 \\ -8 x_6 - 2 & 2 \leq x_6 \leq 200 \end{cases} \quad (3.7)$$

$$f_7(x_7) = \begin{cases} -8 x_7 & 0 \leq x_7 \leq 2 \\ -7 x_7 - 2 & 2 \leq x_7 \leq 4 \\ -5 x_7 - 10 & 4 \leq x_7 \leq 7 \end{cases} \quad (3.8)$$

$$f_8(x_8) = \begin{cases} -11 x_8 & 0 \leq x_8 \leq 1 \\ -10 x_8 - 1 & 1 \leq x_8 \leq 2 \\ -8 x_8 - 5 & 2 \leq x_8 \leq 3 \\ -5 x_8 - 14 & 3 \leq x_8 \leq 4 \\ -4 x_8 - 18 & 4 \leq x_8 \leq 5 \end{cases} \quad (3.9)$$

As inequações (3.1) foram completadas com variáveis de folga $x_9, x_{10}, x_{11}, x_{12}$ às quais atribuímos os seguintes limites:

$$0 \leq x_i \leq 200 \quad , \quad i = 9, 10, 11, 12$$

As contribuições dessas variáveis na função objetivo não influem no seu valor pois estaremos supondo linearidade e com inclinação $C_0^j = 0$, para $j = 9, 10, 11, 12$.

Numa primeira solução partimos da seguinte solução básica não factível ($\underline{x} = \underline{x}^1$):

$$\text{Variáveis Básicas: } \underline{x}_I^T = (x_9, x_{10}, x_{11}, x_{12})$$

$$\underline{x}_I^T = (636, 294, -188, -134)$$

$$\text{Variáveis Não Básicas: } \underline{x}_J^T = (x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8)$$

$$\underline{x}_J^T = (4, 5, 6, 50, 2, 200, 7, 5)$$

$$\text{com } F(\underline{x}^1) = -2076$$

Chegando a uma solução ótima dada por ($\underline{x} = \underline{x}^2$):

$$\text{Variáveis Básicas: } \underline{x}_I^T = (x_6, x_{10}, x_9, x_4)$$

$$\underline{x}_I^T = (18, 13.333, 63.333, 5.333)$$

$$\text{Variáveis Não Básicas: } \underline{x}_J^T = (x_1, x_2, x_3, x_5, x_7, x_8, x_{11}, x_{12})$$

$$\underline{x}_J^T = (4, 5, 0, 2, 7, 5, 0, 0)$$

cujo valor da função objetivo é:

$$F(\underline{x}) = F(\underline{x}^2) = -323$$

Numa segunda solução partimos da seguinte Solução Básica Não Factível ($\underline{x} = \underline{x}^3$) :

Variáveis Básicas: $\underline{x}_I^T = (x_1, x_2, x_3, x_4)$

$$\underline{x}_I^T = (292.675, 223.766, 168.584, -252.104)$$

Variáveis Não Básicas: $\underline{x}_J^T = (x_5, x_6, x_7, x_8, x_9, x_{10}, x_{11}, x_{12})$

$$\underline{x}_J^T = (0, 200, 7, 0, 0, 0, 0, 200)$$

$$\text{com } F(\underline{x}^3) = -1647$$

Chegando a uma solução ótima dada por ($\underline{x} = \underline{x}^4$) :

Variáveis Básicas: $\underline{x}_I^T = (x_6, x_{10}, x_9, x_4)$

$$\underline{x}_I^T = (16, 11.333, 51.333, 5.333)$$

Variáveis Não Básicas: $\underline{x}_J^T = (x_1, x_2, x_3, x_5, x_7, x_8, x_{11}, x_{12})$

$$\underline{x}_J^T = (4, 5, 2, 2, 7, 5, 0, 0)$$

cujo valor da função objetivo é


$$F(\underline{x}) = F(\underline{x}^4) = -323$$

Note que \underline{x}^2 e \underline{x}^4 , embora sejam soluções distintas para o problema (PLP), fornecem um mesmo valor para a função objetivo, $F(\underline{x}) = -323$. Isto caracteriza a existência de uma solução múltipla para o problema (PLP), o que pode também ser comprovado ao avaliarmos a Inclinação de Referência da variável x_3 , Z^3 , que coincide com a Inclinação C_0^3 da função $f_3(x_3)$: $Z^3 = C_0^3 = -8$.


A constatação de uma solução múltipla para o (PLP), como estamos tratando de um método dual, implica em uma degenerescência

para o problema Dual.

Graficamente teríamos o seguinte:



A partir daí, com alterações em C_k^j , podemos chegar a:



Este procedimento foi usado na resolução do (PLP), partindo das seguintes alterações:

- modificação 1 - tomar $C_0^3 = -7$

- modificação 2 - tomar $C_0^3 = -9$

Para a modificação 1, concluímos que:

- Partindo da Solução Básica Não Factível $\underline{x} = \underline{x}^1$ e da outra $\underline{x} = \underline{x}^3$, chegamos à mesma solução ótima dada por:

Variáveis Básicas: $\underline{x}_I^T = (x_6, x_{10}, x_9, x_4)$

$$\underline{x}_I^T = (18, 13.333, 63.333, 5.333)$$

Variáveis Não Básicas: $\underline{x}_J^T = (x_1, x_2, x_3, x_5, x_7, x_8, x_{11}, x_{12})$

$$\underline{x}_J^T = (4, 5, 0, 2, 7, 5, 0, 0)$$

$$\text{com } F(\underline{x}) = -323$$

Para a modificação 2, concluímos que:

- Partindo da Solução Básica Não Factível $\underline{x} = \underline{x}^1$ e da outra $\underline{x} = \underline{x}^3$, chegamos à mesma solução ótima dada por:

Variáveis Básicas: $\underline{x}_I^T = (x_6, x_{10}, x_9, x_4)$

$$\underline{x}_I^T = (16, 11.333, 51.333, 5.333)$$

Variáveis Não Básicas: $\underline{x}_J^T = (x_1, x_2, x_3, x_5, x_7, x_8, x_{11}, x_{12})$

$$\underline{x}_j^T = (4, 5, 2, 2, 7, 5, 0, 0)$$

com $F(\underline{x}) = -325$

Resolvemos a seguir o seguinte problema:

$$\text{Minimizar } F(\underline{x}) = \sum_{j=1}^{12} f_j(x_j)$$

sujeito à:

$$\begin{pmatrix} 1 & -2 & 3 & -1 & 5 & -3 & 1 & -1 & 1 & 0 & 0 & 0 \\ 3 & 1 & -1 & 2 & 2 & -2 & -3 & 4 & 0 & 1 & 0 & 0 \\ -2 & 1 & 1 & 0 & 1 & 1 & 0 & -2 & 0 & 0 & 1 & 0 \\ 5 & -4 & 0 & 3 & -2 & 0 & -1 & 0 & 0 & 0 & 0 & 1 \\ 21 & -13 & 4 & 15 & 4 & -4 & -9 & 1 & 1 & 2 & 3 & 4 \end{pmatrix} \underline{x} = \begin{pmatrix} 10 \\ -8 \\ 7 \\ 5 \\ 67 \end{pmatrix}$$

onde cada $f_j(x_j)$ é dada por (3.2) - (3.9) e para $j = 9, 10, 11, 12$ como exposto anteriormente.

A resolução deste problema nos levou a uma Redundância, o que era de se esperar uma vez que a última linha é uma Combinação Linear das demais.

Um outro exemplo foi resolvido a partir do anterior com uma alteração na última linha, onde apenas o elemento correspondente ao vetor \underline{b} não obedece a combinação linear proposta no exemplo anterior.

Assim, tivemos:

$$\text{Minimizar } F(\underline{x}) = \sum_{j=1}^{12} f_j(x_j)$$

sujeito a:

$$\begin{pmatrix} 1 & -2 & 3 & -1 & 5 & -3 & 1 & -1 & 1 & 0 & 0 & 0 \\ 3 & 1 & -1 & 2 & 2 & -2 & -3 & 4 & 0 & 1 & 0 & 0 \\ -2 & 1 & 1 & 0 & 1 & 1 & 0 & -2 & 0 & 0 & 1 & 0 \\ 5 & -4 & 0 & 3 & -2 & 0 & -1 & 0 & 0 & 0 & 0 & 1 \\ 21 & -13 & 4 & 15 & 4 & -4 & -9 & 1 & 1 & 2 & 3 & 4 \end{pmatrix} \underline{x} = \begin{pmatrix} 10 \\ 8 \\ 7 \\ 5 \\ -68 \end{pmatrix}$$

Esta alteração no problema nos levou a uma Solução Não-Factível para o problema Primal.

Resolvemos ainda um outro exemplo com alterações no sistema original (3.1):

$$\text{Minimizar } F(\underline{x}) = \sum_{j=1}^8 f_j(x_j)$$

sujeito a:

$$\begin{pmatrix} 1 & -2 & 3 & -1 & 5 & -3 & 1 & -1 \\ 3 & 1 & -1 & 2 & 2 & -2 & -3 & 4 \\ -2 & 1 & 1 & 0 & 1 & 1 & 0 & -2 \\ 5 & -4 & 0 & 3 & -2 & 0 & -1 & 0 \\ -7 & 4 & -3 & -4 & -6 & 4 & 3 & -1 \end{pmatrix} \underline{x} \leq \begin{pmatrix} 10 \\ 8 \\ 7 \\ 5 \\ -32 \end{pmatrix} \quad (3.10)$$

onde cada $f_j(x_j)$ é dada por (3.2) - (3.9).

As inequações (3.10) foram completadas com variáveis de folga $x_9, x_{10}, x_{11}, x_{12}, x_{13}$ às quais atribuímos os limites:

$$0 \leq x_i \leq 200, \quad i = 9, 10, 11, 12, 13$$

cuja contribuição não influem no valor da função objetivo pois supomos que as funções destas variáveis são lineares e de inclinação $C_0^j = 0$, $j = 9, 10, 11, 12, 13$.

A resolução deste problema nos levou a uma Solução Não-Factível para o problema Primal. Note que no sistema de inequações (3.10), se tivéssemos tomado a última linha como a soma dos demais teríamos:

$$(7 \quad -4 \quad 3 \quad 4 \quad 6 \quad -4 \quad -3 \quad 1) \underline{x} \leq 30$$

entretanto tomamos:

$$(7 \quad -4 \quad 3 \quad 4 \quad 6 \quad -4 \quad -3 \quad 1) \underline{x} \geq 32$$

para termos caracterizada uma Infactibilidade para o problema.

Assim, pudemos testar todos os tipos de soluções possíveis para o problema:

3.4 - INTERPRETAÇÃO GEOMÉTRICA

Pelo que foi apresentado no capítulo 2, pudemos observar uma Interpretação Geométrica interessante para o método desenvolvido.

Do desenvolvimento que precede as equações (2.31) e (2.32) verifica-se facilmente que:

$$\phi(\underline{p}^* + t \underline{v}_r) = \phi(\underline{p}^*) + t \underline{v}_r (\underline{b} - A^J \underline{d}_{k,J} - A^r x_r^0(t))$$

Da dedução de (2.15) também pode se escrever:

$$\underline{b} - A^J \underline{d}_{k,J} = A^I \underline{x}_I^+$$

donde se conclui que:

$$\phi(\underline{p}^* + t \underline{v}_r) = \phi(\underline{p}^*) + t \underline{v}_r \underline{g}$$

com
$$\underline{g} \stackrel{\Delta}{=} A^I \underline{x}_I^+ - A^r x_r^0(t)$$

sendo \underline{g} o sub-gradiente da função $\Phi(\underline{p})$ no ponto $\underline{p} = \underline{p}^*$, LASDON [1]. Este vetor pode ser colocado em termos dos vetores colunas de A^I , que constituem uma base para o espaço no qual se define \underline{p} .

Assim:

$$\underline{g} = (A^1 \quad A^2 \dots A^r \dots A^m) \begin{pmatrix} x_1^+ \\ \vdots \\ x_r^+ - x_r^0(t) \\ \vdots \\ x_m^+ \end{pmatrix}$$

$$\underline{g} = \sum_{\substack{i=1 \\ i \neq r}}^m A^i x_i^+ + A^r (x_r^+ - x_r^0(t)) \quad (3.11)$$

onde o vetor resultante da somat6ria da equa76o (3.11) pertence ao espa7o nulidade de $\underline{v}_r, \mathcal{N}(\underline{v}_r)$, sendo, por um teorema cl6ssico da 1lgebra Linear, NOBLE [6], ortogonal ao mesmo.

Da7, conclu7mos que:


$$\Phi(\underline{p}^* + t \underline{v}_r) = \Phi(\underline{p}^*) + t \underline{v}_r A^r (x_r^+ - x_r^0(t))$$

Assim, um vetor na dire76o de $-A^r$ faz o papel do gradiente de $\Phi(\underline{p})$, com as seguintes propriedades:

- em cada ponto de quebra que permite uma continua76o da busca, haver6 uma diminui76o do seu m6dulo.
- no ponto de quebra que determina o fim de cada itera76o, haver6 uma invers6o no sentido do mesmo.

- a direção conserva-se inalterada dentro de uma mesma iteração.

Graficamente, para duas dimensões, teríamos:



Na figura acima, os pontos 1, 2, 3 são pontos de quebra intermediários; o ponto 4 é o último ponto de quebra da busca na direção \underline{v}_r .

CAPÍTULO 4

PROGRAMAÇÃO LINEAR POR PARTES

4.1 - INTRODUÇÃO

Neste capítulo faremos uma apresentação da Programação Linear por Partes (PLP), do método de resolução do tipo PRIMAL-SIMPLEX.

Sobre o termo Programação Linear por Partes entenderemos, neste capítulo, o conjunto de métodos para o cálculo do mínimo de uma função linear por partes convexa, definida sobre um poliedro convexo.

A Programação Linear por Partes pode ser vista como um ramo intermediário entre a Programação Linear e a Programação Convexa. Veremos aqui que a Programação Linear por Partes tem seu método de resolução como sendo uma generalização do método PRIMAL-SIMPLEX.

4.2 - APRESENTAÇÃO DO PROBLEMA DE PROGRAMAÇÃO LINEAR POR PARTES

Um problema geral de Programação Linear por Partes pode ser colocado sob a forma:

$$(A) \left\{ \begin{array}{l} \text{Minimizar } F(\underline{x}) \\ \text{sujeito a: } \left\{ \begin{array}{l} H(\underline{x}) \leq 0 \\ A \underline{x} = \underline{b} \\ \underline{x} \in R \end{array} \right. \end{array} \right. \quad \begin{array}{l} (4.1) \\ (4.2) \\ (4.3) \\ (4.4) \end{array}$$

onde R é um poliedro convexo e $H(\underline{x})$ é uma função vetorial do tipo:


$$H(\underline{x}) = \{h_1(\underline{x}), \dots, h_m(\underline{x})\} \quad (4.5)$$

e $F(\underline{x})$ e $h_i(\underline{x})$ ($i = 1, 2, \dots, m$) são funções convexas lineares por partes.

Vamos considerar um caso particular do problema (A) do tipo:

$$(P) \left\{ \begin{array}{l} \text{Minimizar } F(\underline{x}) = \sum_{j=1}^n f_j(x_j) \quad (4.6) \\ \text{sujeito a : } \left\{ \begin{array}{l} A \underline{x} = \underline{b} \quad (4.7) \\ \underline{\alpha} \leq \underline{x} \leq \underline{\beta} \quad (4.8) \end{array} \right. \end{array} \right.$$

com $A(m, n)$ de "rank" m , $\underline{x}(n, 1)$, $\underline{b}(m, 1)$ e $f_j(x_j)$ linear por partes, tal que:



$$f_j(x_j) \triangleq \left\{ \begin{array}{l} c_0^j x_j \quad \alpha_j \leq x_j \leq d_{1,j} \\ (c_0^j + \sigma_1^j) (x_j - d_{1,j}) + f_j(d_{1,j}) \quad d_{1,j} \leq x_j \leq d_{2,j} \\ \vdots \\ (c_0^j + \sum_{i=1}^{l_j} \sigma_i^j) (x_j - d_{l_j,j}) + f_j(d_{l_j,j}) \quad d_{l_j,j} \leq x_j \leq \beta_j \end{array} \right. \quad (4.9)$$

ou

$$f_j(x_j) \triangleq \begin{cases} C_0^J x_j & a_j \leq x_j \leq d_{1,j} \\ C_1^J x_j + g_{1,j} & d_{1,j} \leq x_j \leq d_{2,j} \\ \vdots \\ C_{\ell_j}^J x_j + g_{\ell_j,j} & d_{\ell_j,j} \leq x_j \leq \beta_j \end{cases} \quad (4.10)$$

com $C_k^J \triangleq C_0^J + \sum_{i=1}^k \sigma_i^J$ com $\sigma_i^J > 0$ e $k = 0, 1, \dots, \ell_j$ (4.11)

e $g_{k,j} \triangleq f_j(d_{k,j}) - C_k^J d_{k,j}$ (4.12)

4.3 - MÉTODO DE RESOLUÇÃO DO PROBLEMA (P)

Como este método é uma extensão do método Primal-Simplex para Programação Linear, caminhamos sempre de Solução Básica Factível para Solução Básica Factível.

$\underline{x} = \underline{x}^+$ denotará um valor básico assumido por \underline{x} ao resolver o sistema $A \underline{x} = \underline{b}$

Assim, de $A \underline{x} = \underline{b}$ temos:

$$A^I \underline{x}_I + A^J \underline{x}_J = \underline{b}$$

$$\underline{x}_I = (A^I)^{-1} \underline{b} - (A^I)^{-1} A^J \underline{x}_J$$

$$\underline{x}_I = \underline{x}_I^+ = \underline{\hat{b}} - \hat{A}^J \underline{x}_J^+ \quad (4.13)$$

com $\underline{x}_J^+ = \underline{d}_{k,j}$

Uma Solução Básica:

$$\underline{x} = \underline{x}^+ = \begin{bmatrix} \underline{x}_I^+ \\ \underline{x}_J^+ \end{bmatrix} = \begin{bmatrix} \underline{b} - \tilde{A}^J \underline{d}_{k,J} \\ \underline{d}_{k,J} \end{bmatrix} \quad (4.14)$$

será factível, quando além de satisfazer $A \underline{x} = b$ tivermos também $\underline{\alpha} \leq \underline{x} \leq \underline{\beta}$.

Convém lembrar que a uma base pode corresponder várias Soluções Básicas.

A Solução Básica \underline{x} será não-degenerada se $x_i, i \in I$, não coincide com nenhum dos seus valores críticos: $d_{k,i} < x_i < d_{k+1,i}$.

Diremos que o problema (P) é não-degenerado se cada uma de suas Soluções Básicas Factíveis for não-degenerada.

Nós nos limitaremos ao exame de problemas não-degenerados.

Uma vez determinado o valor de $\underline{x}_I = \underline{x}_I^+$, dado em (4.14), e desde que sabemos ser factível, podemos determinar o Intervalo de Definição de cada $\underline{x}_i^+, i \in I$, e conseqüentemente a Inclinação C_k^i naquele intervalo da função $f_i(x_i), i \in I$.

Sendo \underline{p} um vetor (l, m) , para qualquer \underline{x} factível, o problema (P) é equivalente a:

$$(P') \left\{ \begin{array}{l} \text{Minimizar: } F(\underline{x}) - \underline{p} \underline{b} = \sum_{i \in I} \{f_i(x_i) - \underline{p} A^i x_i\} + \sum_{j \in J} \{f_j(x_j) - \underline{p} A^j x_j\} \\ \text{s.a. : } \begin{cases} \underline{x}_I + \tilde{A}^J \underline{x}_J = \underline{b} \\ \underline{\alpha} \leq \underline{x} \leq \underline{\beta} \end{cases} \end{array} \right.$$

com $\underline{p} A^j \stackrel{\Delta}{=} Z^j$, denominado INCLINAÇÃO DE REFERÊNCIA.

Temos assim que (P) e (P') terão o mesmo conjunto de Soluções Factíveis e os valores de $F(\underline{x})$ em (P) e em (P') serão os mesmos para um mesmo \underline{x} factível.

Vamos então escolher um vetor $\underline{p} = \underline{p}^+$, correspondente à Solução Básica Factível $\underline{x} = \underline{x}^+$, de forma que:

$$\underline{z}^+ \mathbf{I} = \underline{p}^+ \mathbf{A}^I = \underline{c}_k^I$$

Logo:

$$\underline{p}^+ = \underline{c}_k^I (\mathbf{A}^I)^{-1} \quad (4.15)$$

De (P^+) , podemos ainda escrever que:


$$F(\underline{x}^+) - \underline{p}^+ \underline{b} = \sum_{i \in I} g_{k,i} + \sum_{j \in J} \{f_j(x_j^+) - z^{+j} x_j^+\} \quad (4.16)$$

A expressão (4.16), embora válida apenas para $d_{k,i} < x_i < d_{k+1,i}$, $i \in I$, tem a vantagem de apresentar-se em termo das variáveis não básicas x_j , $j \in J$, permitindo assim uma análise local da variação de $F(\underline{x})$ em torno de $\underline{x} = \underline{x}^+$.


Note que podemos proceder esta análise examinando separadamente cada uma das parcelas $\{f_j(x_j) - z^{+j} x_j\}$

Assim, para um certo $j \in J$, quanto aos valores assumidos por z^j podemos ter 3 situações:


a) $z^j > c_k^j$



b) $z^j < c_{k-1}^j$



c) $c_{k-1}^j < z^j < c_k^j$



Com isso mostraremos que na situação (a), podemos diminuir o valor de $F(\underline{x})$, através de um aumento no valor de $x_j = x_j^+$. Na situação (b) diminuiremos $F(\underline{x})$ diminuindo o valor de $x_j = x_j^+$ e na situação (c) não podemos diminuir o valor de $F(\underline{x})$ com alterações em x_j .

- Seja $\underline{x} = \underline{x}^+$ uma Solução Básica Factível para o problema (P').

Seja \underline{x} um vetor tal que:

$$\underline{x}_j = \underline{x}_j^+ + \underline{\epsilon}_j, \text{ com } \underline{\epsilon}_j \text{ suficientemente pequeno.}$$

De $A \underline{x} = \underline{b}$, temos que:

$$\underline{x}_I = \underline{x}_I^+ - \bar{A}^J \underline{\epsilon}_J$$

Então:

$$F(\underline{x}) - \underline{p}^+ \underline{b} = \sum_{i \in I} g_{k,i} + \sum_{j \in J} \{f_j(x_j^+ + \epsilon_j) - z^{+j}(x_j^+ + \epsilon_j)\} \quad (4.17)$$

onde: $f_j(x_j^+ + \epsilon_j) = f_j(x_j^+) + c_Y^j \epsilon_j$

com
$$\gamma(\epsilon_j) = \begin{cases} K & \text{se } \epsilon_j > 0 \\ K-1 & \text{se } \epsilon_j < 0 \end{cases} \quad (4.18)$$

$$F(\underline{x}) - \underline{p}^+ \underline{b} = \sum_{i \in I} g_{k,i} + \sum_{j \in J} \{f_j(x_j^+) - z^{+j} x_j^+\} + \sum_{j \in J} (c_Y^j - z^{+j}) \epsilon_j$$

Portanto:
$$F(\underline{x}) = F(\underline{x}^+) + \sum_{j \in J} (c_Y^j - z^{+j}) \epsilon_j \quad (4.19)$$

Como estamos procedendo a uma análise local, e como a função $F(\underline{x})$ é convexa, um ponto de mínimo local é ponto de mínimo global; esta análise é facilitada pela separabilidade apresentada em (4.19): cada termo $(c_Y^j - z^{+j}) \epsilon_j$ pode ser tratado independentemente.

Assim, se para qualquer $j \in J$, um dos termos $(c_Y^j - z^{+j}) \epsilon_j$ for negativo teremos:

$$- \epsilon_j > 0 \quad \text{e} \quad c_Y^j - z^{+j} < 0$$

Sendo $\epsilon_j > 0 \rightarrow c_Y^j = c_k^j$

Então teremos: $c_k^j - z^{+j} < 0 \rightarrow z^{+j} > c_k^j$ e caímos então

na situação (a) apresentada anteriormente, onde podemos diminuir $F(\underline{x})$ com o aumento do x_j^+ correspondente

$$- \epsilon_j < 0 \quad \text{e} \quad C_Y^j - Z^{+j} > 0$$

$$\text{Sendo } \epsilon_j < 0 \rightarrow C_Y^j = C_{k-1}^j$$

Então: $C_{k-1}^j - Z^{+j} > 0 \rightarrow Z^{+j} < C_{k-1}^j$ e caímos na situação (b), onde podemos diminuir $F(\underline{x})$ com a diminuição do x_j^+ correspondente.

Se ocorrer que nenhum dos termos $(C_Y^j - Z^{+j}) \epsilon_j$ seja negativo, teremos que para todos $j \in J$, $(C_Y^j - Z^{+j}) \epsilon_j > 0$. Não consideraremos o caso de igualdade pois estamos partindo da hipótese de não degenerescência.

Temos que analisar os casos $\epsilon_j > 0$ e $\epsilon_j < 0$.

Para $\epsilon_j > 0$, teremos:

$$C_Y^j - Z^{+j} > 0$$

$$C_k^j - Z^{+j} > 0 \rightarrow Z^{+j} < C_k^j$$

Para o caso em que $\epsilon_j < 0$, $C_Y^j - Z^{+j} < 0$
 $\rightarrow C_{k-1}^j - Z^{+j} < 0 \rightarrow Z^{+j} > C_{k-1}^j$.

Daí tirarmos o critério de otimalidade do problema (P):

$$C_{k-1}^j \leq Z^{+j} \leq C_k^j, \quad (4.20)$$

que é a situação onde $F(\underline{x})$ não pode ser diminuída por qualquer variação de x_j^+ , $j \in J$.

Assim, partamos de uma Solução Básica Factível de (P). O método de resolução consiste em um número finito de iterações, onde cada iteração é constituída de duas etapas:

1ª ETAPA: Teste de otimalidade da Solução Básica presente.

Se ótima, fim

Se não, 2ª ETAPA

2ª ETAPA: Parte-se para uma nova Solução Básica que diminua $F(\underline{x})$.

4.4 - DESCRIÇÃO EM DETALHE DE UMA ITERAÇÃO:


Seja $\underline{x} = \underline{x}^+ = \begin{bmatrix} \underline{x}_I^+ \\ \underline{x}_{J^+} \end{bmatrix}$ uma Solução Básica Factível de (P).

Primeiramente devemos verificar se $\underline{x} = \underline{x}^+$ é solução ótima do problema (P). Para tanto, basta verificarmos se são satisfeitas as condições de otimalidade dadas em (4.20).


Até então estamos tratando com $x_j^+ = d_{k,j}$, $j \in J$, não nos preocupando com os casos $k = 0$ e $k = l_{j+1}$.

Para estes casos podemos dar a seguinte Interpretação Gráfica:

a) $k = 0$



b) $k = \ell_{j+1}$



Conforme mostramos em (a) e (b), se fizermos:

$$c_{-1}^j = -\infty \quad \text{e} \quad c_{\ell_{j+1}}^j = \infty$$

podemos representar o critério de otimalidade apresentado em (4.20) por uma única expressão:

$$c_{k-1}^j \leq z^{+j} \leq c_k^j \quad \text{para } k=1,2,\dots,\ell_j \quad (4.21)$$

Assim, para verificarmos a otimalidade de $\underline{x} = \underline{x}^+$ é suficiente calcular os z^{+j} , $j \in J$, e verificar se satisfazem (4.21).

Se todas as desigualdades se verificam, $\underline{x} = \underline{x}^+$ é solução ótima de (P).

Caso contrário, $\underline{x} = \underline{x}^+$ não é solução ótima de (P), e devemos prosseguir no sentido de minimizar $F(\underline{x})$.

Neste processo vamos impor uma variação de \underline{x}^+ , de modo que provoque a modificação de apenas uma componente do vetor $\underline{x}_j = \underline{x}_j^+$.


Com isso teremos a alteração de apenas uma componente $(c_Y^r - z^{+r}) \varepsilon_r$, $r \in J$, que será escolhida como aquela que nos proporciona a maior TAXA DE DECRESCIMO.

Note que as demais componentes $(C_Y^j - Z^{+j}) \in_j$, $j \in J$ e $j \neq r$, permanecem inalteradas.

4.4.1 - ESTUDO DETALHADO DA SITUAÇÃO a

Neste parágrafo faremos um estudo detalhado para a SITUAÇÃO a apresentada no parágrafo anterior em que: $Z^{+r} > C_k^r > C_{k-1}^r$, e apresentaremos as equações correspondentes à SITUAÇÃO b onde: $Z^{+r} < C_{k-1}^r < C_k^r$, cujo desenvolvimento é análogo ao que será apresentado para a SITUAÇÃO a.

ESTUDO DA SITUAÇÃO a



Nosso objetivo é encontrar uma nova solução básica factível para o problema (P), que nos forneça um valor de $F(\underline{x})$ menor do que o dado anteriormente, uma vez que o objetivo é minimizar $F(\underline{x})$.

Assim:

Seja $\underline{x}(\epsilon)$ um vetor tal que:

$$\underline{x}(\epsilon) = \begin{cases} x_j - \epsilon \bar{A}_j^r & , \quad j \in I \\ x_j + \epsilon & , \quad j=r \text{ e } j \in J \\ x_j & , \quad j \in J - \{r\} \end{cases} \quad (4.22)$$

que também pode ser visto sob a forma:

$$\underline{x}(\epsilon) = \begin{bmatrix} \underline{x}_I \\ \underline{x}_r \\ \underline{x}_{J-\{r\}} \end{bmatrix} + \epsilon \begin{bmatrix} -\bar{A}^r \\ 1 \\ 0 \end{bmatrix}$$

Daí podemos concluir que:

- a) $\underline{x}(\epsilon)$ é uma solução factível para ϵ positivo e suficientemente pequeno.
- b) x_r tende para $d_{k+1,r}$
- c) se $\bar{A}_s^r > 0$, $s \in I$, temos que x_s tende para $d_{k,s}$
- d) se $\bar{A}_s^r = 0$, $s \in I$, temos que x_s é insensível ao aumento de ϵ .
- e) se $\bar{A}_s^r < 0$, $s \in I$, temos que x_s tende para $d_{k+1,s}$

Temos, portanto, $(m+1)$ possíveis limites de ϵ a serem alcançados.

A expressão:

$\Delta F(\underline{x}) = F(\underline{x}) - F(\underline{x}^+) = (C_k^r - Z^{+r}) \epsilon$ deixaria de valer logo que um deles fosse alcançado.

A limitação do crescimento de ϵ pode ser dada pela variável r ou por uma variável básica.

Devemos tomar $\epsilon = \min \{\epsilon_r, \epsilon_i \quad \forall i \in I\}$.

Vamos analisar separadamente os dois casos:

A) A limitação do crescimento de ϵ é dada pela variável r .

$$x_r(\epsilon) = d_{k+1,r}$$

$$x_r + \epsilon_r = d_{k+1,r}$$

$$\epsilon_r = d_{k+1,r} - x_r$$

$$\epsilon_r = d_{k+1,r} - d_{k,r} \quad (4.23)$$

B) A limitação do crescimento de ϵ é dada pela variável s , sei

Temos aqui dois casos a analisar:

$$B.1) \bar{A}_s^r > 0$$

$$B.2) \bar{A}_s^r < 0$$

$$B.1) \bar{A}_s^r > 0 \rightarrow x_s(\epsilon) = d_{k,s}$$

$$x_s - \epsilon_s \bar{A}_s^r = d_{k,s}$$

$$\epsilon_s = \frac{x_s - d_{k,s}}{\bar{A}_s^r} \quad (4.24)$$

$$B.2) \bar{A}_s^r < 0 \rightarrow x_s(\epsilon) = d_{k+1,s}$$



$$x_s - \epsilon_s \bar{A}_s^r = d_{k+1,s}$$

$$\epsilon_s = \frac{x_s - d_{k+1,s}}{\bar{A}_s^r} \quad (4.25)$$

Dada a diminuição de $F(\underline{x})$, devemos verificar o que acontecerá após um Ponto Crítico na função $F(\underline{x})$, se continuarmos aumentando o valor de ϵ . A idéia é continuar o crescimento de ϵ de forma a concluir a transição situação a \rightarrow situação c.

O que vai ocorrer após o Ponto Crítico dependerá do tipo de Ponto Crítico verificado.

1º TIPO): O valor Crítico é dado pela variável r .



Então:

$\exists \varepsilon_1 > 0$ tal que:

$$\varepsilon_1 = d_{k+1,r} - d_{k,r}$$

e $d_{k,i} < x_i - \varepsilon_1 \bar{A}_i^r < d_{k+1,i}$, $\forall i \in I$

Devemos testar o comportamento da função para um pequeno acréscimo de ϵ_1 .

É bom lembrar que quando a limitação de ϵ é dada pela variável r , Z^{+r} permanece inalterado enquanto o C_Y^r passa a valer C_{k+1}^r uma vez que x_r passa de $d_{k,r}$ para $d_{k+1,r}$.

Assim, chamando: TDN = Taxa de Decréscimo Nova
TDA = Taxa de Decréscimo Antiga,

$$TDA = C_k^r - Z^{+r}$$

$$TDN = C_{k+1}^r - Z^{+r}$$

$$\text{Então, } TDN = TDA + \sigma_{k+1}^r \quad (4.26)$$

- Caso esta TDN ainda seja negativa, isso indica que podemos aumentar o valor de ϵ até o próximo limitante que está garantido uma diminuição da função $F(\underline{x})$.



Se esta TDN for não negativa, devemos parar com a Busca Unidimensional, pois não haverá mais diminuição da Função $F(\underline{x})$.

No caso de ocorrência do 1º TIPO, o valor de Z^{+r} permanece inalterado e a diferença entre C_Y^r e Z^{+r} diminui porque a nova diferença será $(C_{k+1}^r - Z^{+r})$, que é menos negativa que a diferença anterior $(C_k^r - Z^{+r})$. Com isso, Z^{+r} está mais próxima das Inclinações Adjacentes a um dado valor crítico, caminhando assim para a OTIMALIDADE (SITUAÇÃO c)

2º TIPO): O Valor Crítico é dado pela variável s , se I.

Aqui, como já mostramos anteriormente, temos que levar em consideração o sinal de \hat{A}_s^r .

Tomemos então o caso $\hat{A}_s^r > 0$



Então:

$\exists \epsilon_1 > 0$ tal que:

$$\epsilon_1 < d_{k+1,r} - d_{k,r}$$

$$\epsilon_1 = \frac{x_s - d_{k,s}}{\hat{A}_s^r}$$

$$d_{k,i} < x_i - \epsilon_1 \bar{A}_i^r < d_{k+1,i} \cdot v_i, \quad i \in I - \{s\}$$

Devemos testar o comportamento da função para um pequeno acréscimo de ϵ_1 .

Aqui, é bom lembrar que dada a limitação de ϵ pela variável $s \in I$, o $C_Y^r = C_k^r$ não se altera, estando a alteração verificada em Z^{+r} pois:

$$(Z^{+r})_{\text{antigo}} = (\underline{C}_k^I)_{\text{antigo}} \bar{A}^r$$

$$(Z^{+r})_{\text{novo}} = (\underline{C}_k^I)_{\text{novo}} \bar{A}^r$$

mas, $(\underline{C}_k^I)_{\text{novo}} = (\underline{C}_k^I)_{\text{antigo}} - (0, 0, \dots, \sigma_k^s, 0 \dots 0)$

$$\text{Então: } (Z^{+r})_{\text{novo}} = (Z^{+r})_{\text{antigo}} - \sigma_k^s \bar{A}_s^r \quad (4.27)$$

De (4.19) temos que:

$$TDA = C_k^r - (Z^{+r})_{\text{antigo}}$$

$$TDN = C_k^r - (Z^{+r})_{\text{novo}}$$

Assim:

$$TDN = TDA + (Z^{+r})_{\text{antigo}} - (Z^{+r})_{\text{novo}}$$

ou seja: $TDN = TDA + \sigma_k^s \bar{A}_s^r \quad (4.28)$



Caso a TDN seja negativa, indica que podemos crescer ϵ até o próximo limitante que temos garantido uma diminuição em $F(\underline{x})$.

Caso contrário, paramos com a Busca Unidimensional pois não haverá mais diminuição no valor de $F(\underline{x})$.

Neste caso $C_Y^r = C_k^r$ não se altera, sendo que a alteração

é dada em Z^{+r} , que segundo a expressão (4.27) terá seu valor diminuído, aproximando-se das Inclinações Adjacentes a um dado valor crítico, havendo com isso uma tendência de atingir a OTIMALIDADE (SITUAÇÃO c).

Ainda no 2º TIPO vamos abordar o caso $\bar{A}_s^r < 0$



Para este caso temos que:

$\exists \epsilon_1 > 0$ tal que:

$$\epsilon_1 < d_{k+1,r} - d_{k,r}$$

$$\epsilon_1 = \frac{x_s - d_{k+1,s}}{\bar{A}_s^r}$$

$$d_{k,i} < x_i - \epsilon_1 \bar{A}_i^r < d_{k+1,i}, \quad \forall i, \quad i \in I - \{s\}$$

Aqui teremos:

$$(C_k^I)_{\text{novo}} = (C_k^I)_{\text{antigo}} + (0, 0, \dots, \sigma_{k+1}^s, 0, \dots, 0)$$

$$e \quad (Z^{+r})_{\text{novo}} = (Z^{+r})_{\text{antigo}} + \sigma_{k+1}^s \bar{A}_s^r$$

e de (4.19) teremos:

$$TDA = C_k^r - (Z^{+r})_{\text{antigo}}$$

$$TDN = C_k^r - (Z^{+r})_{\text{novo}}$$

$$\text{Logo:} \quad TDN = TDA - \sigma_{k+1}^s \bar{A}_s^r \quad (4.29)$$

Se TDN for negativa, indica que a função $F(\underline{x})$ decresce para esse aumento de ϵ_1 e, então devemos crescer ϵ até o próximo limitante.

Caso contrário paramos com a Busca Unidimensional, pois $F(\underline{x})$ não decresce mais com o aumento de ϵ .

Desenvolvimento análogo poderia ser apresentado para a

SITUAÇÃO b citada no parágrafo anterior onde, os valores de ϵ seriam negativos.

As expressões obtidas são análogas às apresentadas para a SITUAÇÃO a, exceto pequenas alterações nos valores dos σ_Y^j correspondentes a cada caso. Também são válidas as mesmas observações quanto às TAXAS DE DECRESCIMO da função $F(x)$, lembrando porém que elas são, em princípio, POSITIVAS.

BIBLIOGRAFIA

- [1] - LASDON, L.S. - Optimization Theory for Large Systems - Macmillan - 1970.
- [2] - YODINE, D & GOLSTEIN, E. - Problèmes Particuliers de la Programmation Linéaire - Edition MIR - 1973.
- [3] - LUENBERGER, D.G. - Introduction to Linear and Nonlinear Programming - Addison Wesley - 1973.
- [4] - SAKAROVITCH, M. - Notes on Linear Programming - Van Nostrand Reinhold Company - 1975.
- [5] - FERNANDES, J.F.R. & AUTHIE, G. - Commande Optimale Décentralisée pour les Systèmes Linéaires Discrets à Retards Distribués - IFAC - Workshop on Large Systems, Industrial Applications, TOULOUSE - SET/77.
- [6] - NOBLE, B. - Applied Linear Algebra - Prentice Hall - 1969.