

UMA VERSÃO FINITA DO MÉTODO C.F.A.

Carlos Humes Jr.

Departamento de Ciência da Computação
Instituto de Matemática e Estatística
Universidade de São Paulo

SUMÁRIO

O resultado aqui apresentado é o de validade de um algoritmo "projeção - direções viáveis" que se caracteriza por substituir no C.F.A. clássico a solução do problema de designação de fluxos por um único desvio de fluxo, com passo máximo sem preocupar-se com a manutenção de viabilidade deste fluxo, perante a capacidade fixada naquela iteração.

Para este algoritmo valem as seguintes observações:

- (1) tal como o C.F.A. clássico (projeção - projeção) computa um ponto estacionário de Kuhn-Tucker.
- (2) a convergência, em termos de número de iterações é finita.
- (3) a cada iteração resolve-se uma designação de capacidades e um desvio de fluxo (parte de uma iteração para a solução de designação de fluxos) diminuindo sensivelmente o custo de cada iteração.

Este resultado é baseado na demonstração de que o valor ótimo do problema de designação de capacidades, em função dos fluxos indicados, é uma função quasicôncava e que, portanto, toda direção de descida local é direção de descida global.

1. INTRODUÇÃO

A formulação tradicional do problema de projeto de redes de computadores considera que é dado o conjunto N de localizações dos nós comutadores de mensagens, a demanda média de transmissão de mensagens e suas características para cada par (origem, destino). De posse destes dados busca-se determinar tanto o roteamento das mensagens (qual o caminho que seguem ou, equivalentemente, quais os fluxos de mensagens nos vários canais), quanto a capacidade de transmissão (velocidade) de cada um dos canais a serem instalados. Nesta formulação, pode-se considerar que o conjunto de possíveis interconexões é variável de projeto (projeto topológico) ou que é dado (o que é a tônica desta apresenta; ou seja, o problema de designação de fluxos e capacidades).

Para avaliar o projeto temos que definir critérios, critérios estes que caracterizaram os pontos focais de abordagem. Evitando maiores discussões que podem ser encontradas em GERLA [1] e HUMES [2], consideraremos o implícito problema bicritério onde as funções objetivo são custo e tempo médio de encaminhamento de mensagem entre origem e destino. Estes critérios serão modelados por funções $D(c) =$ custo dos m canais instalados com capacidades c_i , $i = 1, 2, \dots, m$, e $T(f,c) =$ retardo com roteamentos associado a um fluxo de mensagens $f = (f_1 \dots f_m)^t$ e capacidades instaladas $(c_1, c_2, \dots, c_m)^t$.

A notação acima, pressupõe que existem m canais possíveis de interconexão, correspondendo ao projeto topológico. 0

projeto topológico corresponde a definirmos o esquema de interconexão entre os nós comutadores de mensagens. Esta definição é naturalmente modelada através de um grafo $G = (N, \tilde{A})$ onde \tilde{A} , conjunto dos arcos do grafo G , representa a existência de canais de comunicação entre os nós (comutadores).

Como \tilde{A} é finito, não há perda de generalidade em utilizarmos $\tilde{A} = \{1, 2, \dots, m\}$ caracterizando os extremos das arestas por

$$\tilde{a} : \tilde{A} \rightarrow \{(i, j) \subset 2^N \mid i > j\} \equiv Q$$

Note-se que a definição acima (Q), implica em não considerarmos canais cuja origem e destino coincidam (hipótese esta bastante natural). Na mesma linha, suporemos $\tilde{a}(\cdot)$ injetora (canais em paralelo são tratados como canal de maior capacidade).

Na medida em que considerarmos os canais *full-duplex* e formos estudar fluxos é conveniente considerar o digrafo associado \tilde{a} interconexão. Digrafo este cujas arestas orientadas são dadas por:

$$a : \tilde{A} \rightarrow \{(i, j) \in N \times N\}$$

caracterizadas por

$$a(i) = \{(k, 1), (1, k)\} \Leftrightarrow \tilde{a}(i) = \{k, 1\}$$

O conjunto de arestas do digrafo será indicado por A ,

onde

$$A = \bigcup_{i \in \bar{A}} a(i) = a(\bar{A}) .$$

Considerando como dados:

$N = \{1, 2, \dots, n\}$ = conjunto de localizações de nós comutadores de mensagens, isto é, pontos onde um ou mais dos canais de comunicação tem extremos,

$q : N \times N \rightarrow R_+$ = demanda média de transmissão entre os nós comutadores de mensagem. Tipicamente esta demanda é medida em kilobits/seg.*,

$\bar{q} : N \times N \rightarrow R_+$ = demanda média de envio de mensagens entre os nós comutadores. Tipicamente, esta demanda é medida em milhares de mensagens/seg.*,

$\bar{l} : N \times N \rightarrow R_{++}$ = comprimento médio das mensagens entre os nós comutadores* ,

*. Por simplicidade de notação usaremos

$$q_{ij} = q((i, j)), \quad q = \sum_{i \in N} \sum_{j \in N} q_{ij},$$

$$\bar{q}_{ij} = \bar{q}((i, j)), \quad \bar{q} = \sum_{i \in N} \sum_{j \in N} \bar{q}_{ij},$$

$$\bar{l}_{ij} = \bar{l}((i, j)).$$

Mais ainda, faremos as seguintes hipóteses simplificadoras:

$$\bar{l}_{ij} \stackrel{\approx}{=} \frac{1}{\mu} \text{ (homogeneidade no tamanho de mensagens);}$$

$$q_{ij} = \frac{1}{\mu} \bar{q}_{ij} \text{ (independência de processos);}$$

$$q_{jj} = 0, \quad \bar{q}_{jj} = 0, \text{ para } j \in N.$$

podemos então definir o problema de projeto de redes de computadores como:

"Dados N e $q : N \times N \rightarrow R_+$, encontre, se existir, a região de pontos eficientes (ou um subconjunto desta região) em relação ao critério $(T(f, c), d(c))^t$, obedecendo às restrições

$$(R1) f^{rs} \in F^{rs} = \{ \bar{f} \in R_+^{2m} \mid \sum_{l:(k,l) \in A} \bar{f}_{kl} - \sum_{l:(l,k) \in A} \bar{f}_{lk} = (\delta_{kr} - \delta_{ks}) q_{rs} \}$$

para $(r, s) \in N \times N$ (com $q_{rs} > 0^*$;

$$(R2) f_{ij} = \sum_{(r,s) \in N \times N} f_{ij}^{rs}, \text{ para } (i, j) \in A;$$

$$(R3) f_i = f_{k1} + f_{1k}, \text{ para } \hat{a}(i) = (k, 1);$$

$$(R4) \forall i \in \hat{A}, (f_i, c_i) \in Y_i = \{(0, 0)\} \cup \{(x, y) \in R \times C_i \mid 0 \leq x < y\},$$

onde C_i é dado;

(R5) \hat{A} é um conjunto de arcos com extremos em N , gozando, conforme a formulação, de uma propriedade P^* .

As restrições (R1) e (R2) correspondem a modelar um fluxo multicomodidade (*multi-commodity flow*) onde cada tipo de comodidade (unidade de transmissão) é caracterizada por sua origem e destino.

* Caso contrário, $f_{ij}^{rs} = 0$, para todos os arcos $(i, j) \in A$.

A restrição (R3) corresponde a uma modelagem clássica para canais *full-duplex*, onde o sentido em que a unidade de transmissão percorre o canal não é determinante de seu efeito no fluxo.

Em alguns pontos, será conveniente notar que estamos trabalhando com vetores $\bar{f} \in R_+^{2m}$, tais que $\bar{f} \in \Sigma_{(r,s) \in N \times N} F^{rs}$ e com vetores $f \in R^m$, onde $f_i = \bar{f}_{k1} + \bar{f}_{1k}$ para $a(i) = \{k, 1\}$. Porém, nos reservamos o direito de, a menos de necessidade para a clareza do texto, usar a expressão " $f = (f_1, f_2, \dots, f_m)^t$ é a soma de fluxos multicomodidade".

Note-se que nas condições acima não há perda de generalidade em assumir que:

$$r \leq s \Rightarrow q_{rs} = 0 \Leftrightarrow F^{rs} = \{0 \in R^{2m}\}$$

Mais ainda, deve ser claro que em qualquer solução eficiente

$$\forall (k, 1) \in A, \forall (r, s) \in N \times N, f_{k1}^{rs} \cdot f_{1k}^{rs} = 0$$

A restrição (R4) indica que o canal inativo ($f_i = 0$) pode não existir fisicamente ($c_i = 0$) e que, exceto neste caso, o grau de congestionamento (f_i/c_i) é bem definido e pertence ao intervalo $[0, 1)$.

A questão de canais inativos poderem não existir fisicamente é complexa ao considerarmos que na restrição (R5) poderíamos impor condições tais como biconexidade sobre o grafo (N, \bar{A}) . Uma possível solução para tal questão seria impor restrições do

tipo $f_i \geq \bar{f}_i$ ou $c_i \geq \bar{c}_i$ para $i \in \bar{A}$. O segundo tipo de restrições pode fazer sentido no caso $C_i = \{0, c_{1i}, c_{2i}, \dots, c_{pi}\}$.

Para evitar maiores problemas, consideraremos \bar{A} como dado e seguindo a abordagem usual para problemas bicritério (ver, p. ex., LIN [3] e [4]), consideremos os problemas abaixo:

$$\begin{aligned} & \text{minimizar } \sum_{i=1}^m d_i(c_i) \\ & \sum_{i=1}^m t_i(f_i, c_i) \leq \bar{q} T_{\text{MAX}} \\ \text{PD } (T_{\text{MAX}}) \quad & (f_i, c_i) \in Y_i \\ & f \in F; \end{aligned}$$

$$\begin{aligned} & \text{minimizar } \sum_{i=1}^m t_i(f_i, c_i) \\ & \sum_{i=1}^m d_i(c_i) \leq D_{\text{MAX}} \\ \text{PT } (D_{\text{MAX}}) \quad & (f_i, c_i) \in Y_i \\ & f \in F; \end{aligned}$$

onde F é o poliedro das somas de fluxos multicomodidades descritas pelas restrições (R1) a (R3) de F e estamos considerando $\bar{A} = \{1, 2, \dots, m\}$ dado. Claramente supomos $F \neq \emptyset$. Estes problemas são denominados problemas de designação de fluxo e capacidade (CFA - Capacity and Flow Assignment).

Neste trabalho nos concentraremos no caso $C_i = [0, +\infty)$, chamado de relaxação contínua ou caso contínuo.

Por simplicidade, nós consideramos acima que o custo da rede é somente o custo dos canais de transmissão, ou mais preci

samente, a soma dos custos individuais dos canais. Utilizando a notação $D(\cdot)$ para o custo total e $d_i(\cdot)$ para o custo dos canais individuais, é claro que

$$D(\cdot) = \sum_{i=1}^m d_i(\cdot) .$$

Os custos individuais dos canais são definidos nos valores possíveis de capacidades ($d_i : C_i \rightarrow R_+$), mas, não há perda em generalidade em supor:

$$\forall i \in \bar{A}, d_i : R_+ \rightarrow R_+ .$$

Em termos simplistas, a hipótese acima conflita com, por exemplo, $C_i = p \in N$. Neste caso, existiria uma infinidade de funções custo $d_i : R_+ \rightarrow R_+$ que retratariam a estrutura de custos restrita às capacidades disponíveis.

Mas, é natural supor que as funções $d_i(\cdot)$ procurem representar fenômenos econômicos e que desta forma sejam gerados seus valores. Assim sendo, suporemos ao longo deste trabalho:

(H1) $d_i(0) = 0$ (capacidade nula \Leftrightarrow canal não instalado \Leftrightarrow custo nulo);

(H2) $\lim_{x \rightarrow +\infty} d_i(x) = +\infty$ (não há limite superior para os custos a menos que as capacidade sejam limitadas);

(H3) $x > y \geq 0 \Rightarrow d_i(x) > d_i(y) \geq 0$ (custos monotonicamente crescentes);

(H4) $d_i(\cdot)$ é C^∞ em $(0, +\infty)$ (com continuidade simples na fronteira);

Além destas hipóteses usaremos freqüentemente:

(H5) $d_i(\cdot)$ é côncava ou (H5A) $d_i(\cdot)$ é estritamente côncava;

(H6) $d_i(\cdot)$ é côncava na origem ou (H6A) $d_i(\cdot)$ é estritamente côncava na origem.

A não obrigatoriedade das hipóteses de concavidade está associada ao nosso interesse em obter resultados teóricos sem estas hipóteses. A hipótese que corresponde a uma technicalidade é a hipótese (H4). Defendemos fortemente a validade desta hipótese, no caso geral, pois acreditamos que os modelos de geração de preços pelos serviços de comunicação utilizem funções para as quais (H4) vale.

No caso brasileiro, temos

$$d_i(x) = l_i c^\alpha,$$

onde

(i) $\alpha \in (0, 1)$, i.é., $\alpha = 0,56$;

(ii) l_i depende da distância em quilômetros entre os extremos do canal de comunicação.

É interessante notar que este resultado foi obtido inicialmente por análise de tabelas da EMBRATEL e confirmada posteriormente em contatos com profissionais desta organização.

Em relação ao retardo, consideramos válida a hipótese de existência de uma forma produto para as probabilidades de

mensagens nos buffers do nós chamadores de mensagens, ou seja, (p. ex., ver KLEINROCK [5]):

$$T(f, c) = \frac{1}{\bar{q}} \sum_{i=1}^m t_i(f_i, c_i) = T$$

No caso particular de retardo médio em redes de filas M/M/1 teremos

$$T = \sum_{i=1}^m \frac{\lambda_i}{\bar{q}} \quad T_i = \sum_{i=1}^m \frac{1}{\bar{q}} \frac{\lambda_i}{\mu} \frac{1}{c_i - f_i} = \frac{1}{\bar{q}} \sum_{i=1}^m \frac{f_i}{c_i - f_i}$$

Isto é, para retardo médio em redes de filas M/M/1, teremos

$$t_i(f_i, c_i) = \frac{f_i}{c_i - f_i}$$

As funções $t_i(\cdot, \cdot)$ não apresentam um caráter qualquer por representarem parcelas do fenômeno físico de retardo. Assim sendo, ao longo do trabalho suporemos que algumas hipóteses são a elas aplicáveis. Estas hipóteses, para $i = 1, 2, \dots, m$, são:

(H7)* $t_i : Y \rightarrow R_+$, onde $Y = \{(0, 0)\} \cup Y_0$ e $Y_0 = \{(f, c) \mid 0 \leq f < c\}$, $t_i(0, \cdot) = 0$;

(H8) $t_i : Y_0 \rightarrow R_+$ é C^∞ (com os devidos cuidados na fronteira);

(H9) $\forall M > 0, t_i(f, c) = t_i(Mf, Mc)$;

* As hipóteses H1 a H6 dizem respeito à estrutura de custos.

(H10) $\forall \bar{c} > 0, t_i(-, \bar{c}) : Y \cap \{(a, \bar{c} - 1 a \in R) \rightarrow R_+$ é

(a) estritamente convexa

(b) monotonicamente crescente (no sentido estrito)

(c) $\lim_{f \rightarrow \bar{c}^-} t_i(f, \bar{c}) = +\infty.$

(H11) $\forall \bar{f} > 0, t_i(\bar{f}, \cdot) : Y \cap \{(\bar{f}, a) \mid a \in R\} \rightarrow R_{++}$ é

(a) estritamente convexa

(b) monotonicamente decrescente (no sentido estrito)

(c) $\lim_{c \rightarrow \bar{f}^+} t_i(\bar{f}, c) = +\infty.$

A hipótese (H7) especifica que o grau de congestionamento deve ser menor do que a unidade e que canais não ativos ($f_i = 0$) não contribuem para nossa medida de retardo (mais ainda, neste caso, a melhor opção é a não instalação do canal, isto é, $c_i = 0$).

A hipótese (H8) é meramente técnica e refletida nos modelos de filas usuais. A hipótese (H9) de homogeneidade de grau zero está intrinsicamente ligada à idéia de que os $t_i(-, -)$ são adimensionais retratando a parcela do canal i na composição de $\bar{q} T e$, portanto, não podem ser influenciados por "mudanças de escala" na aferição de c_i e f_i .

As hipóteses (H10) e (H11) representam o comportamento natural de sistemas com congestão.

Uma observação é que deve ser notado que a homogeneidade de grau zero implica em descontinuidade em $(0, 0)$. Existem im-

precisões na literatura devido à ausência deste cuidado.

2. RESULTADOS PRELIMINARES

Para os problemas acima definidos, valem os seguintes resultados, para a relaxação contínua.

Fato 2.1 PD (T_{MAX}) é viável qualquer que seja $T_{MAX} > 0$ e PT (D_{MAX}) é viável qualquer que seja $D > D^0$ onde $D^0 = \inf \left\{ \sum_{i=1}^m d_i(f_i) \mid f \in F \right\} > 0$.

Demonstração: trivial a partir das hipóteses (H1) a (H4) e (H7), (H8), (H10) e (H11), notando que $D^0 = \min \left\{ \sum_{i=1}^m d_i(f_i) \mid f \in F \right\}$.

O mínimo acima indicado é bem definido, pois F é um poliedro na forma canônica $F \equiv \{[V(F)] + C_F\}$ e como $d_i(\cdot)$ é monótonica estritamente crescente,

$$\begin{aligned} D^0 &= \inf \left\{ \sum_{i=1}^m d_i(f_i) \mid f \in F \right\} = \\ &= \inf \left\{ \sum_{i=1}^m d_i(f_i) \mid f \in [V(F)] \right\} = \\ &= \min \left\{ \sum_{i=1}^m d_i(f_i) \mid f \in [V(F)] \right\} \quad \square \end{aligned}$$

Para o caso contínuo podemos ainda afirmar:

Fato 2.2 Para todo $T_{MAX} > 0$ e $D_{MAX} > D_0$, os problemas

PT (D_{MAX}) e PD (T_{MAX}) têm solução ótima.

Demonstração

Apresentaremos a prova em duas partes distintas:

(i) $T_{MAX} > 0 \Rightarrow$ PD (T_{MAX}) tem solução ótima.

Antes de mais nada notemos que a restrição $0 < f_i < c_i$ pode ser substituída por $f_i \leq \bar{\rho}_i c_i$ onde $\bar{\rho}_i$ é definido por $t_i(\bar{\rho}_i, 1) \leq T_{MAX}$. Claramente, $\bar{\rho}_i \in [0, 1)$.

Tal fato é possível pois para $c_i > 0$, por (H9)

$$t_i(f_i, c_i) = t_i(f_i/c_i, 1).$$

Mais ainda, por (H10), $t_i(\cdot, 1)$ é estritamente crescente e por (H7), $t_k(\cdot, \cdot) \geq 0$.

Portanto, a restrição $(f_i, c_i) \in Y_i$ pode ser substituída por

$$(f_i, c_i) \in \{(a, b) \in \mathbb{R}_+^2 \mid a \leq \bar{\rho}_i b\}.$$

Mais ainda, se (\bar{f}, \bar{c}) é um ponto viável de PD (T_{MAX}) podemos, sem perda de generalidade, impor a hipótese adicional $c_i \leq c_i^+$ onde c_i^+ é definido por $d_i(c_i^+) = \sum_{j=1}^m d_j(\bar{c}_j)$.

A existência de c_i^+ é garantida por (H1) a (H4).

Assim sendo, PD (T_{MAX}) pode ser reescrito como

$$\text{minimizar } \sum_{i=1}^m d_i(c_i)$$

$$(f_i, c_i) \in K_i = \{(a, b) \mid 0 \leq a \leq b, \bar{p}_i \leq c_i\}$$

$$\sum_{i=1}^m t_i(f_i, c_i) \leq \bar{q} T_{\text{MAX}}$$

$$f \in F$$

Claramente K_i é compacto e portanto o conjunto de pontos viáveis está contido no compacto $K \equiv K_1 \times K_2 \times \dots \times K_m$.

Mais ainda, por (H8) $t_i(\cdot, \cdot)$ é contínua em todos os pontos de K_i , exceto $(0, 0)$. Mas, neste ponto, qualquer que seja a seqüência $\{(f_i^k, c_i^k)\}_{k \in \mathbb{N}}$, $(f_i^k, c_i^k) \in K_i$, convergindo para $(0, 0)$, temos

$$t_i(f_i^k, c_i^k) \geq 0 = t_i(0, 0)$$

portanto, $t_i(\cdot, \cdot)$ é semicontínua inferior em K_i .

Podemos então, afirmar que $\sum_{i=1}^m t_i(\cdot, \cdot)$ é semicontínua inferior em K e, portanto, $\{(f, c) \in K \mid \sum_{i=1}^m t_i(f_i, c_i) \leq \bar{q} T_{\text{MAX}}\}$ é fechado em K e, portanto, é compacto.

Como F é fechado e $\sum_{i=1}^m d_i(\cdot)$ é contínua (H4), segue que estamos minimizando uma função contínua em um compacto não vazio (o ponto (\bar{f}, \bar{c}) viável, utilizado via axioma da escolha pertence ao compacto construído). Portanto, existe solução ótima do problema. \square

(ii) D_{MAX} tem solução ótima.

A argumentação é similar à apresentada acima, sendo que a restrição de custo impõe o limite superior nas capacidades, um ponto viável gera um retardo utilizado para definir os \bar{p}_i , $i = 1 \dots m$, e a compacidade dos pontos viáveis segue da continuidade das restrições de custo e de fluxo (lineares).

Como o retardo é limitado inferiormente ($t_i(\cdot, \cdot) \geq 0$) e semicontínuo inferior, com a compacidade obtida segue a existência de mínimo. \square

A importância deste resultado fica clara ao enunciarmos o seguinte fato, para o caso contínuo:

Fato 2.3 Para todo $T > 0$, o ponto $(T, D^*(T))$, onde

$D^*(T) = \text{valor ótimo de PD}(T)$

é um projeto eficiente.

Antes de demonstrar este fato, provemos o seguinte lema válido para o caso contínuo:

Lema 2.4 Para todo $T > 0$, se (f^*, c^*) é solução ótima de PD (T) então $T(f^*, c^*) = T$.

Demonstração: suponhamos, por contradição, que $T(f^*, c^*) < T$. Então podemos diminuir c_1^* para $\bar{c}_1 = c_1^* - \Delta_1$, de modo que

$$t_1(\bar{c}_1, f_1^*) = t_1(c_1^*, f_1^*) + T - T(f^*, c^*).$$

Isto é possível por (H11) e (H8).

Então por (H3) obtemos um ponto viável com custo inferior ao da solução ótima. O que é uma contradição. \square

Com este lema em mente, segue a demonstração de

Demonstração de (2.3): suponhamos, por contradição, que $(T, D^*(T))$ não é eficiente, isto é, é possível encontrar um vetor $(\bar{f}, \bar{c})^t$ tal que $(F(\bar{f}, \bar{c}), D(\bar{c})) \leq (T, D^*(T))$.

Se $T(\bar{f}, \bar{c}) < T$ então (\bar{f}, \bar{c}) é viável em PD(T) e $D(\bar{c}) = D^*(T)$. Portanto (\bar{f}, \bar{c}) solve PD(T) e por $T(\bar{f}, \bar{c}) = T$, o que é uma contradição.

Se $T(\bar{f}, \bar{c}) = T$, então $D(\bar{c}) < D^*(T)$, o que negaria a definição de $D^*(T)$. \square

De forma completamente análoga provam-se os seguintes fatos válidos para o caso contínuo.

Fato 2.5 Para todo $D > D_0$, o ponto $(T^*(D), D)$, onde

$$T^*(D) = \text{valor ótimo de } PT(D)$$

é um projeto eficiente.

Lema 2.6 Para todo $D > D_0$, se (f^*, c^*) é solução ótima de $PT(D)$, então $D(c^*) = \sum_{i=1}^m d_i (c_i^*) = D$.

As demonstrações são omitidas por serem variações simples das provas anteriores.

Estes resultados iniciais correspondem a um aproveitamento parcial de peculiar estrutura matemática do problema em estudo. Sob o ponto de vista de Programação Matemática de Grande

Porte, devemos ainda destacar as estruturas de separabilidade, monotonicidade e conversidades parciais.

As funções custo e retardo são somas de parcelas atribuíveis a cada canal específico. As funções custo por canal são monotonicas crescentes e, usualmente, côncavas. Os retardos por canal são funções que com um argumento fixo são estritamente convexas e extritamente monotônicas. Mais ainda, se pudéssemos desprezar a restrição de retardo, teríamos dois grupos de variáveis com completa independência. Neste caso, a aproximação contínua teria valor ótimo obviamente igual a $(\sum_{i=1}^m d_i(f_i))$ caso o problema fosse viável. Em relação ao retardo, existe a estrutura adicional de que $t_i(\cdot, \cdot)$ é função homogênea de grau zero.

Este conjunto de considerações despertaram o nosso interesse e, em particular, induziram-nos a aceitar a abordagem usual da literatura, projeção. Note-se que a projeção natural corresponde a trabalhar alternadamente nos subespaços de fluxos e de capacidades, resolvendo alternadamente problemas projetados que são denominados problema de designação de capacidades (CA) (fluxo fixo) e problema de designação de fluxo (FA) (capacidades fixas). Estes problemas são definidos como:

O problema de designação de capacidades é aquele obtido através da particularização do problema de designação de fluxos e capacidades ao prefixarmos um fluxo multicomodidade. Isto é, (CA) é obtido a partir de PD (T_{MAX}) ou PT (D_{MAX}), impondo $F \equiv \{\bar{F}\}$.

Nestas condições, obtemos os problemas CD (T_{MAX}) e

CT (D_{MAX}) definidos por

$$\min \sum_{i=1}^m d_i (c_i)$$

$$CD (T_{MAX}) = \sum_{i=1}^m t_i (F_i, c_i) \leq \bar{q} T_{MAX}$$

$$c_i \in C_i \text{ e } c_i > F_i \quad i = 1, 2, \dots, m$$

$$\min \sum_{i=1}^m t_i (F_i, c_i)$$

$$CT (D_{MAX}) = \sum_{i=1}^m d_i (c_i) \leq D_{MAX}$$

$$c_i \in C_i \text{ e } c_i > F_i \quad i = 1, 2, \dots, m$$

Note-se que estamos assumindo, sem perda de generalidade, $F_i > 0$.

O problema de designação de fluxos (FA) é aquele obtido através da particularização do problema de designação de fluxos e capacidades ao prefixarmos as capacidades instaladas. Isto é, (FA) é obtido a partir de PT (D) impondo $C_i = \{\bar{c}_i\}$, $i = 1, 2, \dots, m$ e $D(c) = \sum_{i=1}^m d_i(\bar{c}_i)$.

Assim sendo, o problema (PA), para $c = \bar{c}$, é definido por

$$\min \sum_{i=1}^m t_i (f_i, \bar{c}_i)$$

$$f \in F$$

(FA)

$$c_i > f_i, \text{ para } i \in I(\bar{c})$$

$$f_i = 0, \text{ para } \bar{c}_i = 0.$$

onde F é o poliedro de fluxos multicomodidade descrito pelas restrições (R1) a (R3) de

Recordando o já exposto:

$$(R1) f^{rs} \in F^{rs} = \{F \in \mathbb{R}_+^{2m} \mid \sum_{l:(k,l) \in A} F_{kl} - \sum_{l:(l,k) \in A} F_{lk} = (\delta_{kr} - \delta_{ks}) q_{rs}\}$$

$$(R2) f_{ij} = \sum_{(r,s) \in N \times N} f_{ij}^{rs}, \text{ para } (i, j) \in A,$$

$$(R3) f_i = f_{k1} + f_{1k}, \text{ para } \bar{a}(i) = \{k, 1\}.$$

Note-se que não há perda de generalidade em assumir $I(\bar{c}) = \{1, 2, \dots, m\}$.

O problema de designação de fluxos é um problema não-linear convexo de fluxos multicomodidade. Apesar de dificuldades naturais associadas a porte, este problema é bem comportado no sentido de que para ele teoremas fortes de dualidade (tanto minimax como Wolfe) são válidos. Mais ainda, todo mínimo local é global.

O problema de designação de capacidades tem duas versões: contínua e discreta. No caso discreto, é um problema de mochila não-linear. No caso contínuo, o (CA) aparente ter a dificuldade de apresentar mínimos locais que não são globais (devido à concavidade de $d_i(\cdot)$). exceto no caso simples de custos lineares. Tais dificuldades são aparentes e em HUMES [2] elas são eliminadas com a introdução de uma hipótese adicional. Dizemos que vale a hipótese adicional para a estrutura de custos

e retardos (HA) para o problema de projeto, se

$$\forall i = 1, 2, \dots, m, \forall \bar{F}_i > 0, \forall \bar{c}_i > F_i;$$

$$\begin{aligned} & \frac{d^2}{dc_i^2} d_i(c_i) - \frac{d}{dc_i} t_i(\bar{F}_i, c_i) - \\ & - \frac{d^2}{dc_i^2} t_i(\bar{F}_i, c_i) - \frac{d}{dc_i} d_i(c_i) \Big|_{c_i = \bar{c}_i} < 0 \end{aligned}$$

ou, mais sumariamente,

$$d''(\bar{c}_i) t'_i(\bar{c}_i) - t''(\bar{c}_i) d'(\bar{c}_i) < 0 \quad \square$$

Note-se que se o custo for linear, a convexidade estrita do retardo e a monotonicidade crescente do custo implica na validade da hipótese adicional.

É interessante notar que para o caso mais estudado na literatura, que é o de filas M/M/1 com custo dado por *power law*, a hipótese adicional (HA) é válida.

Mas, um ponto que devemos ter em mente é que um ponto (f^*, c^*) tal que f^* resolve o (FA) com $C_i = \{c_i^*\}$ e c^* resolve o (CA) com $F = \{f^*\}$ não é necessariamente sequer um mínimo local, como é afirmado erroneamente na literatura.

3. DESIGNAÇÃO DE FLUXOS E CAPACIDADES USANDO PROJEÇÃO

No seu clássico artigo de 1970, GEOFFRION [6] introdu-

ziu as idéias manipulação e estratégias, para o tratamento de problemas de grande porte em programação matemática. Uma das manipulações destacadas é a chamada projeção, com a qual já tratamos implicitamente ao estudar a utilização de programação dinâmica no (CA) discreto (ver, por exemplo, HUMES [4]).

Tipicamente, dado o problema (PTP)

$$\min f(x, y)$$

$$(PTP) \text{ sujeito a } g(x, y) \leq 0$$

$$x \in X, y \in Y$$

a manipulação de projeção deste problema, sobre o espaço das variáveis y , como:

$$\min v(y)$$

$$(PAP_y) =$$

$$\text{sujeito a } y \in Y \cap V,$$

onde:

$$V = \{y \in Y \mid \exists x \in X : g(x, y) \leq 0\},$$

$$v : V \rightarrow R \{-\infty\} \text{ é definida por}$$

$$v(\bar{y}) = \inf \{f(x, \bar{y}) \mid x \in X \text{ e } g(x, \bar{y}) \leq 0\}.$$

A técnica de projeção é naturalmente aplicável ao problema de designação de fluxos e capacidades, desde que seja tomado

o cuidado técnico do tratamento da restrição $c > f$.

Basicamente a idéia é que para $c = \bar{c}$ (ou $f = \bar{f}$) para o qual o problema seja viável, isto é, $\bar{c} \in V$ ($\bar{f} \in V$), existe um limitante superior do retardo e pode-se substituir $c > f$ por $\bar{c} \geq kf$ (ou $c \geq k\bar{f}$).

Os principais resultados necessários a uma fácil aplicação do método de projeção estão associados aos seguintes fatos:

Fato 3.1 Os problemas $PD(T)$ e $PT(D)$, se viáveis, têm solução ótima tanto no caso $C_i = [0, +\infty)$ como no caso $C_i = 0, c_{i1}, \dots, c_{ip}$, $i = 1, 2, \dots, m$.

Demonstração: no caso contínuo é repetição de 2.2. No caso discreto, é óbvio pela finitude de capacidades disponíveis. \square

Fato 3.2 Se o ponto (f^*, c^*) é solução ótima de $PD(T)$ ($PT(D)$), então

- (a) c^* é solução ótima de $CD(T)$ ($CT(D)$) com $f = f^*$;
- (b) f^* é solução ótima de (FA) , com $c = c^*$.

Demonstração: óbvia. \square

Os fatos acima indicam a existência de solução ótima para $PD(T)$ e $PT(D)$ e que, caso usemos projeção sobre as capacidades ou sobre os fluxos, o ínfimo presente na definição de $V(\cdot)$ é um mínimo.

A abordagem tradicional para a solução (ou tentativa de solução) do problema de designação de capacidades e fluxos é o

método (CFA) que a partir de um fluxo viável f^0 gera a seqüência $\{(c^i, f^i)\}_{i \in \mathbb{N}}$ definida por

$$c^i = \text{solução ótima do (CA), com } f = f^{i-1};$$

$$f^i = \text{solução ótima do (FA), com } c = c^i.$$

Este método pode ser visto como um de dupla projeção e é o encontrado na literatura, como p. ex., KLEI;RPCK [5] e GERLA [1].

A consideração pragmática de que o custo da solução do (CA) é de ordem de grandeza inferior ao da solução do (FA) nos leva a sugerir que utilizemos um método acoplado a estratégia de direções viáveis com a manipulação de projeções sobre o espaço das variáveis fluxo. Em termos imprecisos, a partir de um fluxo viável f^0 , geraríamos uma seqüência $\{(c^i, f^i)\}_{i \in \mathbb{N}}$, tal que

$$c^i = \text{solução ótima do (CA), com } f = f^{i-1} \in F$$

$$f^i = (f^i + \lambda_i h^i) \in F,$$

com a propriedade de melhora do critério para cada par (f^i, c^i) . Isto é, para PD (T), $D(c^{i+1}) < D(c^i)$ e para PT (D), $T(f^{i+1}, c^{i+1}) < T(f^i, c^i)$.

Proporemos a seguir o método desta família e analisaremos seu comportamento para o caso contínuo. Por facilidade de expressão usaremos só a expressão projeção para significar projeção sobre o espaço das variáveis fluxo.

Para podermos estudar esta abordagem temos que analisar a existência de soluções ótimas e o comportamento do valor óti-

mo do problema de designação de capacidades, para vários valores de fluxo multicomodidade f .

Para tal indiquemos os seguintes fatos:

Fato 3.3 Os problemas CD (T_{MAX}) e CT (D_{MAX}) são viáveis para

$$T_{MAX} > T_0 = \inf \left\{ \sum_{i=1}^m t_i(f_i, c_i) \mid c_i > \bar{F}_i \text{ e} \right. \\ \left. c_i \in C_i, i = 1, 2, \dots, m \right\}$$

$$D_{MAX} > D = \inf \left\{ \sum_{i=1}^m d_i(c_i) \mid c_i > \bar{F}_i \text{ e} \right. \\ \left. c_i \in C_i, i = 1, 2, \dots, m \right\}$$

sendo que para o caso discreto $T_{MAX} = T_0$ e $D_{MAX} = D_0$ também são condições de viabilidade. Para o caso contínuo ($C_i \equiv R_+$), temos $T_0 = 0$ e $D_0 = \sum_{i=1}^m d_i(f_i)$.

Demonstração: omitida por ser trivial no caso discreto, numa particularização de (2.1) no caso contínuo e uma simples constatação no caso geral. \square

Fato 3.4 Se o problema CD (T_{MAX}) (CT (D_{MAX})) é viável, então possui solução ótima, tanto no caso discreto como no contínuo.

Demonstração: omitida por ser trivial no caso discreto e uma simples particularização de (2.2) no caso contínuo. \square

Na realidade, o resultado (3.4) é válido para o caso ge-

método (CFA) que a partir de um fluxo viável f^0 gera a seqüência $\{(c^i, f^i)\}_{i \in \mathbb{N}}$ definida por

$$c^i = \text{solução ótima do (CA), com } f = f^{i-1};$$

$$f^i = \text{solução ótima do (FA), com } c = c^i.$$

Este método pode ser visto como um de dupla projeção e é o encontrado na literatura, como p. ex., KLEI;RPCK [5] e GERLA [1].

A consideração pragmática de que o custo da solução do (CA) é de ordem de grandeza inferior ao da solução do (FA) nos leva a sugerir que utilizemos um método acoplado a estratégia de direções viáveis com a manipulação de projeções sobre o espaço das variáveis fluxo. Em termos imprecisos, a partir de um fluxo viável f^0 , geraríamos uma seqüência $\{(c^i, f^i)\}_{i \in \mathbb{N}}$, tal que

$$c^i = \text{solução ótima do (CA), com } f = f^{i-1} \in F$$

$$f^i = (f^i + \lambda_i h^i) \in F,$$

com a propriedade de melhora do critério para cada par (f^i, c^i) . Isto é, para PD (T), $D(c^{i+1}) < D(c^i)$ e para PT (D), $T(f^{i+1}, c^{i+1}) < T(f^i, c^i)$.

Proporemos a seguir o método desta família e analisaremos seu comportamento para o caso contínuo. Por facilidade de expressão usaremos sô a expressão projeção para significar projeção sobre o espaço das variáveis fluxo.

Para podermos estudar esta abordagem temos que analisar a existência de soluções ótimas e o comportamento do valor óti-

ral onde C_i é fechado, o que pode ser demonstrado com pequena variação nos argumentos da demonstração de (2.2).

Entre os dois problemas $CD(\cdot)$ e $CT(\cdot)$ há fortes relações no sentido de que ambos são condições necessárias de otimalidade para $PD(\cdot)$ e $PT(\cdot)$, portanto ambos são condições necessárias para Pareto eficiência de projeto e valem os análogos triviais de (2.5) e (2.6).

O caso contínuo nos permite um conjunto de resultados mais potentes. Portanto, ao longo desta seção, faremos a hipótese $C_i \equiv R_+$. Por exemplo, nestas condições

Fato 3.5 Para uma solução ótima de $CD(T_{MAX})$ ($CT(D_{MAX})$) a restrição de retardo (custo) é obedecida com igualdade.

Demonstração: omitida por ser particularização de

Fato 3.6 Sob a hipótese adicional HA, as funções v_D e v_T abaixo definidas são convexas, subdiferenciáveis e semicontínuas inferiormente, onde:

$v_D : (T \in R \mid T > 0) \rightarrow R$ é definida por:

$$v_D(T) = \inf \left\{ \sum_{i=1}^m d_i(c_i) \mid \sum_{i=1}^m t_i(\bar{F}_i, c_i) \leq \bar{q}T \text{ e } c_i > \bar{F}_i \right\},$$

e

$v_T : (D \in R \mid D > D_0) \rightarrow R$ é definida por:

$$v_T(D) = \inf \left\{ \sum_{i=1}^m t_i(\bar{F}_i, c_i) \mid \sum_{i=1}^m d_i(c_i) \leq D \text{ e } c_i > \bar{F}_i \right\}.$$

Demonstração: Vide HUMES [2].

Esta propriedade foi verificada empiricamente no pioneiro trabalho de GERLA [1] para redes de filas M/M/1 com custos do tipo $(\sum_{i=1}^m l_i c_i^\alpha)$, onde $\alpha \in (0, 1)$.

Esta forte propriedade de convexidade e subdiferenciabilidade, levou-nos a esforços grandes (e mal-direcionados, em nossa presente opinião) para obter soluções do problema por esquemas próximos às idéias de decomposição de Benders.

Estas idéias parecem-nos mal direcionadas, pelo menos se acopladas à projeção usual, pois Benders está ligado à presença de suportes convexos e, portanto, à subdiferenciabilidade (se impusermos suportes diferenciáveis ou subdiferenciáveis) e, portanto, a convexidade. Convexidade esta, cuja principal característica é a "globalidade" de mínimos locais.

Estes comentários torna-se-ão mais claros perante o próximo fato e seu uso posterior. Antes, porém, de podermos enunciar o fato significativo, há que introduzir a definição imediatamente abaixo:

Definição 3.7 As funções custo ótimo $D^*(\cdot, \cdot)$ e retardo ótimo $T^*(\cdot, \cdot)$ em função do fluxo e , respectivamente, do retardo máximo e do orçamento máximo são definidas por:

$$D^*(f, T) = \inf \{ \sum_{i \in I(f)} d_i(c_i) \mid \sum_{i \in I(f)} t_i(f_i, c_i) \leq \bar{q} T \text{ e} \\ c_i > f_i \text{ para } i \in I(f) \},$$

$$T^*(f, T) = \inf \{ \sum_{i \in I(f)} t_i(f_i, c_i) \mid \sum_{i \in I(f)} d_i(c_i) \leq D \text{ e}$$

$$c_i > f_i \text{ para } i \in I(f) \}.$$

onde

$$I(f) = \{ i \in \bar{A} \mid f_i > 0 \}.$$

Por conveniência, nós trabalharemos somente com pares $(f, T) \in F \times R_{++}$ e com pares $(f, D) = F \times \{ x \in R \mid x \sum_{i \in I(f)} d_i(f_i) \}$. Nestas condições, o \inf presente em ambas definições torna-se um mínimo.

Com estas definições em mente, podemos afirmar:

Fato 3.8 Para todo real estritamente positivo T , a função $D^*(\cdot, T) : F \rightarrow R$ é côncava. Mais ainda, se vale (H5A) (custos estritamente côncavos), então $D^*(\cdot, T)$ é estritamente côncava em F .

Demonstração: há várias formas de provar este resultado, mas a que consideramos mais simples e interessante é aquela em que tratamos o problema $CD(T)$ como sendo um de designação de graus de congestionamento $\rho_i = f_i/c_i$.

É trivial verificar, usando (3.4) que

$$\forall f \in F, \forall T > 0,$$

$$\begin{aligned} D^*(f, T) &= \min \{ \sum_{i \in I(f)} d_i(c_i) \mid \sum_{i \in I(f)} t_i(f_i, c_i) \leq \bar{q} T \text{ e} \\ &\quad f_i > c_i \text{ para } i \in I(f) \} \\ &= \min \{ \sum_{i \in I(f)} d_i(f_i/\rho_i) \mid \sum_{i \in I(f)} t_i(\rho_i, 1) \leq \bar{q} T_{MAX} \text{ e} \\ &\quad \rho_i \in (0, 1) \text{ para } i \in I(f) \} \\ &= \min \{ \sum_{i \in I(f)} d_i(f_i/\rho_i) \mid \rho \in RO(f) \} \end{aligned}$$

onde

$$RO(f) = \{ \rho \in R^m \mid \sum_{i \in I(f)} t_i (\rho_i, 1) \leq T_{MAX} \text{ e} \\ \rho_i \in (0, 1) \text{ para } i = 1, 2, \dots, m \}$$

Para tal constatação basta lembrar que

$$\forall x \in (0, 1), d_{i, \frac{0}{x}}(0/x) = d_i(0) = 0, \quad i = 1, 2, \dots, m \text{ por (H)}.$$

Portanto, $\forall \lambda \in (0, 1), \forall (f^1, f^2) \in F \times F$ convexo;
 $f^1 \neq f^2$, se utilizarmos a notação $f(\lambda) = \lambda f^1 + (1 - \lambda) f^2$, te-
 mos

$$D^*(f(\lambda), T) = \min \left\{ \sum_{i=1}^m d_i(f_i(\lambda)/\rho_i) \mid \rho \in RO(f(\lambda)) \right\}.$$

Mais ainda, $\forall i \in I(f(\lambda)) = I(f^1) \cup I(f^2)$, e
 $\forall z \in (0, 1)$

$$d_i(f_i(\lambda)/z) \geq \lambda d_i(f_i^1/z) + (1 - \lambda) d_i(f_i^2/z) \quad (\text{por (H5)})$$

Note-se que, se (H5A) vale, a desigualdade estrita vale e que para $i \notin I(f_\lambda)$, $d_i(f_i(\lambda)/z) = 0$.

Portanto, como

$$(I(f(\lambda)) \equiv I(f^1) \cup I(f^2) \Rightarrow RO(f^i) \subset RO(f(\lambda)), \\ i = 1, 2,$$

segue que

$$\begin{aligned}
D^*(f(\lambda), T) &= \min \left\{ \sum_{i=1}^m \lambda d_i (f_i^1/\rho_i) + (1-\lambda) d (f_i^2/\rho_i) \mid \rho \in \text{RO}(f(\lambda)) \right\} \\
&= \min \left\{ \sum_{i=1}^m d_i (f_i^1/\rho_i) \mid \rho \in \text{RO}(f(\lambda)) \right\} \\
&\quad + (1-\lambda) \left\{ \sum_{i=1}^m d_i (f_i^2/\rho_i) \mid \rho \in \text{RO}(f(\lambda)) \right\} \\
&= \lambda D^*(f^1, T) + (1-\lambda) D^*(f^2, T)
\end{aligned}$$

Sendo que a primeira desigualdade é estrita caso (H5A) valha. \square

É interessante notar que as únicas propriedades de F utilizadas foram convexidade de F e que $f \in F \Rightarrow f \geq 0$. Portanto, o resultado acima enunciado para $D^*(\cdot, T) : F \rightarrow R$ é válido para $D^*(\cdot, T) : R_+^m \rightarrow R$.

Esta constatação é a base para a seguinte afirmação:

Fato 3.9 Para todo real estritamente positivo T , para toda partição (I, J) de $\{1, 2, \dots, m\}$,

$$D^*(\cdot, T) = \{f \in R^m \mid f_i > 0 \text{ para } i \in I, \text{ e } f_j = 0 \text{ para } i \in J\} + R$$

é contínua e superdiferenciável.

Demonstração: no caso $I = \{1, 2, \dots, m\}$ e $J \equiv \emptyset$, o resultado segue trivialmente do fato de que funções côncavas definidas em abertos são contínuas e superdiferenciáveis.

Para o caso J não vazio, o raciocínio é o mesmo utilizando-se como espaço o subespaço linear $\{f \in R^m \mid f_j = 0 \text{ para } i \in J\}$

$j \in J$) e o interior relativo a este subespaço, sendo que as coordenadas j ($j \in J$) do supergradiente são indeterminadas. \square

A restrição de trabalharmos com fluxos f com exatamente as mesmas componentes não nulas nos permite enunciar um resultado de concavidade estrita no caso de custos lineares e redes de filas M/M/1:

Fato 3.10 No caso de custos lineares e redes de filas M/M/1, a função

$$D^*(\cdot, T) : \{f \in F \mid f_j = 0 \Leftrightarrow j \in J\} \rightarrow R$$

é C^∞ e estritamente côncava, para todo real estritamente positivo T .

Demonstração: vide HUMES [2].

O Fato 3.10 permite-nos reforçar parcialmente (3.8), enunciando

Fato 3.11 No caso de redes de filas M/M/1, a função

$$D^*(\cdot, T) : \{f \in F \mid f_j = 0 \Leftrightarrow j \in J\}$$

é estritamente côncava.

Demonstração: sem perda de generalidade, suponhamos $I(f) = \{1, 2, \dots, m\}$ para $f \in \bar{F} = \{f \in F \mid f_j = 0 \Leftrightarrow j \in J\}$.

Sejam $(f^1, f^2, \lambda) \in \bar{F} \times \bar{F} \times (0, 1)$ e c^* a solução ótima de CD(T) para $f = f(\lambda) = \lambda f^1 + (1 - \lambda) f^2$.

Claramente $c^* \in R_{++}^m$ e, portanto, $D(c)$ é superdiferenciável em c^* , pois, por (H5), $D(\cdot)$ é côncava. Nestas condições,

$$\forall c \in R_{++}^m \quad D(c) \leq D_L(c) = D(c^*) + \langle \gamma, c - c^* \rangle.$$

Por (3.10),

$$\begin{aligned} D_L^*(\lambda f^1 + (1 - \lambda) f^2, T) &> \lambda D_L^*(f^1, T) + \\ &+ (1 - \lambda) D_L^*(f^2, T) \\ &\geq \lambda D^*(f^1, T) + (1 - \lambda) D^*(f^2, T) \end{aligned}$$

onde

$$\begin{aligned} D_L^*(f, T) &= \min \{ D_L(c) \mid \sum_{i=1}^m t_i (f_i, c_i) \leq \bar{q} T \text{ e} \\ &c_i > f_i, \quad i = 1, 2, \dots, m \} \end{aligned}$$

e, claramente,

$$D_L^*(\lambda f^1 + (1 - \lambda) f^2, T) = D^*(\lambda f^1 + (1 - \lambda) f^2, T)$$

e, portanto, segue a tese. \square

No presente ponto, duas questões tornam-se naturais: o que podemos afirmar sobre $T^*(\cdot, D)$ e qual o comportamento de $D^*(\cdot, T)$ ($T^*(\cdot, D)$) quando alguma componente do fluxo anula-se.

Quanto ao comportamento de $T^*(\cdot, D)$ os resultados obtidos não são tão fortes quanto os obtidos para $D^*(\cdot, T)$. Esta afirmação é de certo modo frustrante, pois as funções $T^*(\cdot, D)$ e $D^*(\cdot, T)$ estão intimamente ligadas por:

Fato 3.12 Para todo $f \in F$, valem as seguintes relações

$$(a) \forall T > 0, T^*(f, D^*(f, T)) = T$$

$$(b) \forall D > D(f), D^*(f, T^*(f, D)) = D$$

Demonstração: trivial a partir de (3.3) e (3.4). \square

A única aparente assimetria em (a) e (b) acima é a imposição de $D > D(f)$. Esta assimetria torna-se presente ao considerarmos combinações convexas de fluxos, pois, excessão feita ao caso linear (custos lineares), não podemos afirmar que $\{f \in F \mid D(f) > D\}$ é convexo. Intruitivamente, afirmaríamos o oposto, isto é, que se os custos são estritamente côncavos, existiriam sempre $(f^1, f^2) \in F \times F$ tais que $D(f^i) > D$, $i = 1, 2$ e $D(0,5 f^1 + 0,5 f^2) < D$. Em termos mais precisos, podemos enunciar:

Fato 3.13 Para todo real (positivo) D , o conjunto $\{f \in F \mid D(f) \geq D\}$ é convexo.

Demonstração: trivial pela concavidade do custo (H5). \square

Com estas considerações, podemos apresentar uma versão mais fraca de (3.8), a qual é:

Fato 3.14 Para todo real $D > \{\inf D(f) \mid f \in F\}$ a função

$$T^*(\cdot, D) : \{f \in F \mid D\} \rightarrow R$$

é quasicôncava, isto é, sendo

$$A = \{f \in F \mid D(f) < D\},$$

$$\forall (f^1, f^2, \lambda) \in A \times A \times (0, 1) : (\lambda f^1 + (1 - \lambda) f^2) \in A$$

$$T^*(\lambda f^1 + (1 - \lambda) f^2, D) \geq \min_{i=1,2} \{T^*(f^i, D)\}.$$

Demonstração: por simplicidade, utilizamos

$$T^i = T^*(f^i, D), \quad i = 1, 2;$$

$$T_\lambda = T^*(f(\lambda), D),$$

onde

$$f(\lambda) = \lambda f^1 + (1 - \lambda) f^2$$

Suponhamos, sem perda de generalidade, $T^1 \leq T^2$ e que, por contradição, existe λ , tal que $T_\lambda < T^1 \leq T^2$. Então

$$D = D^*(\lambda f^1 + (1 - \lambda) f^2, T_\lambda) \quad (\text{por 3.12})$$

$$\geq \lambda D^*(f^1, T_\lambda) + (1 - \lambda) D^*(f^2, T_\lambda) \quad (\text{por 3.8})$$

$$\geq \lambda D^*(f^1, T^1) + (1 - \lambda) D^*(f^2, T^2) \quad (\text{pois } T_\lambda < T^1 \leq T^2)$$

$$= D \quad (\text{por 3.12}) \quad \square$$

Note-se que com o mesmo raciocínio de (3.14) podemos enunciar:

Fato 3.15 Para todo real $D > \inf \{D(f) \mid f \in F\}$, a função

$$T^*(\cdot, D) : \{f \in F : D(f) < D\} \rightarrow \mathbb{R}$$

é estritamente quasicôncava.

Demonstração: omitida por ser idêntica a (3.14), substituindo $(T_\lambda \leq T^1 < T^2)$. \square

A questão natural que surge é sobre a quasiconcavidade de $T^*(\cdot, D)$ em F .

Claramente, se (f^1, f^2) goza da propriedade $D(f^i) \geq D$, por (3.13) $\forall \lambda \in (0, 1)$, $f(\lambda) = \lambda f^1 + (1 - \lambda) f^2$ goza da propriedade $D(f(\lambda)) \geq D$.

Neste caso, com a convenção $(+\infty \geq +\infty)$, a caracterização de quasiconcavidade mantém-se.

Portanto, nos interessa o caso onde $D(f^1) < D$ e $D(f^2) \geq D$. Neste caso vale:

Fato 3.16 Sejam $(f^1, f^2) \in F$, tais que $D(f^1) < D$ e $D(f^2) \geq D$, então: existe $\bar{\lambda} \in [0, 1)$, tal que

$$(i) D(\lambda f^1 + (1 - \lambda) f^2) < D \iff \lambda > \bar{\lambda},$$

$$(ii) D(\bar{\lambda} f^1 + (1 - \bar{\lambda}) f^2) = D.$$

Demonstração: trivialmente, pela continuidade de $D(\cdot)$,

$$A = \{ \lambda \in [0, 1) \mid D(\lambda f^1 + (1 - \lambda) f^2) \geq D \}$$

+e fechado.

Pela continuidade de $D(\cdot)$ e por $D(1 f^1 + (1 - 1) f^2) < D$, A possui limite superior menor que 1 e, portanto, é bem definido

$$\bar{\lambda} = \sup \{ \lambda \in A \} < 1 \quad \text{e} \quad D(\bar{\lambda} f^1 + (1 - \bar{\lambda}) f^2) = D \quad \square$$

Fato 3.17 Nas condições de (3.16), $\exists \epsilon > 0$, tal que

$$\forall \lambda \in (\bar{\lambda}, \bar{\lambda} + \epsilon], \quad T^*(f(\lambda), D) > T^*(f^1, D).$$

Demonstração: como $D(f^2) > D(f^1)$, podemos assumir, sem perda de generalidade, que $f_1^2 > f_1^1$ e, portanto, $f_1(\lambda)$ é decrescente com λ .

Consideremos \bar{c} definido por

$$t_1(f_1(0,5(1 + \bar{\lambda})), \bar{c}) = T^*(f^1, D),$$

cuja existência é garantida por (H8) a (H11), e seja

$$d_1 = d_1(\bar{c}) > 0, \quad \text{pois} \quad f_1^2 > f_1^1 \geq 0$$

Seja $D' = D - d_1$.

Pela continuidade de $D(\cdot)$ e pela definição de A e $\bar{\lambda}$, como em (3.16) segue que $\exists \epsilon' > 0$, tal que

$$\forall \lambda \in (\bar{\lambda}, \bar{\lambda} + \epsilon], \quad D > D(f(\lambda)) \geq D^*.$$

Tomando $\epsilon = \min\{c^*, 0,5(1 - \bar{\lambda})\}$, temos que, sendo $c^*(\lambda)$ a solução ótima de $C\bar{F}(D)$,

$$T^*(f(\lambda), D) \geq t_1(f_1(\lambda), c_1^*(\lambda)),$$

$$d_1(c_1^*(\lambda)) < D - D(f(\lambda)) \quad D - D^* = d_1.$$

Portanto, $c^*(\lambda) < \bar{c}$.

Como $f_1(\lambda)$ é decrescente com λ , $\forall \lambda \in (\bar{\lambda}, \bar{\lambda} + \epsilon]$

$$\begin{aligned} T^*(f(\lambda), D) &\geq t_1(f_1(\lambda), c_1^*(\lambda)) \\ &> t_1(f_1(0,5(1 + \bar{\lambda})), c_1^*(\lambda)) \\ &> t_1(f_1(0,5(1 + \bar{\lambda})), \bar{c}) \\ &= T^*(f^1, D) \quad \square \end{aligned}$$

Utilizando (3.16) e (3.17) é fácil provar que

Fato 3.18 Para todo real (positivo) D , a função

$$T(\cdot, D) : F \rightarrow \mathbb{R} \cup \{\infty\}$$

é estritamente quasicôncava.

Demonstração: omitida por ser trivial. \square

O resultado aparentemente desejável de que $T^*(\cdot, D)$ fosse côncava é falso em geral, como pode ser verificado com um exemplo simples no caso de custos lineares e redes de filas M/M/1.

Estes fatos aparentemente bizantinos, nos permitem apresentar um algoritmo mais simples que o de dupla projeção e que possui a propriedade de convergência em um número finito de passos.

A base deste algoritmo é apresentada pelos fatos que se seguem.

Fato 3.19 Seja \bar{c} a solução do CT (D) (CD (T) com $f = \bar{f}$). Se para o (FA), com $c = \bar{c}$, existe uma direção de descida no ponto \bar{f} , então esta é uma direção de descida para $T^*(\cdot, D)$ ($D^*(\cdot, T)$) no ponto $f = \bar{f}$.

Demonstração: a demonstração para $T^*(\cdot, D)$ é calcada no fato de que uma queda de retardo para direções de descida.

A demonstração para $D^*(\cdot, T)$ é consequência do fato de que se existe uma direção de descida, para o ponto $f = \bar{f}$, no (FA) com $c = \bar{c}$

$$D^*(\bar{f} + \lambda h, T) \leq D(\bar{c}) = D^*(\bar{f}, T)$$

e

$$T(\bar{f} + \lambda h, \bar{c}) < T,$$

para λ em uma vizinhança da origem e $\lambda > 0$. \square

Fato 3.20 Seja $w : F \rightarrow R$ uma função quasicôncava em F

e seja h uma direção de descida para $w(\cdot)$ em $f \in F$. Isto é,
 $\exists (\bar{\lambda}, \bar{h}) \in \mathbb{R}_{++} \times (F - F)$, tal que

$$(i) \forall \lambda \in [0, \bar{\lambda}], (f + \lambda \bar{h}) \in F$$

$$(ii) \forall \lambda \in [0, \bar{\lambda}], w(f + \lambda \bar{h}) < w(f),$$

então $\forall \lambda \geq 0$, tal que $(f + \lambda \bar{h}) \in F$

$$w(f + \lambda \bar{h}) < w(f).$$

Demonstração: supondo, por contradição, que $\exists \alpha > 0$:

$$(f + \alpha \bar{h}) \in F$$

$$w(f + \alpha \bar{h}) \geq w(f),$$

então existe $p \in [0, 1]$, tal que

$$w(p(f + \alpha \bar{h}) + (1 - p)f) \geq w(f),$$

e

$$0 < p\alpha < \bar{\lambda}$$

o que gera a contradição. \square

A relevância do Fato 3.20 é clara se lembrarmos que $T^*(\cdot, D)$ é quasicôncava em F e $D^*(\cdot, T)$ é (estritamente) côncava e portanto quasicôncava em F .

Nestas condições propomos o seguinte método:

Método 3.21 Seja f^0 um fluxo viável no problema de designação de capacidades (isto é, $D(f^0) > D$ para $PT(D)$ ou $T > 0$ para o $PD(T)$).

Passo 1) Normalização

Encontre c^0 solução do problema de designação de capacidades.

Para $c = c^0$, para todo \bar{a} par (r, s) , com $q_{rs} > 0$, encontre uma árvore de caminho mais custo, com distâncias

$$\alpha_{kl} = \alpha_{lk} = \alpha_i = \frac{(\partial t_i)(f_i^0, c_i^0)}{\partial f_i} \quad \text{para } \bar{a}(i) = \\ = \{k, l\}, \quad i = 1, 2, \dots, m$$

Envie todas as mensagens de k a l pelo caminho mais curto encontrado, para todos os pares (k, l) . Caso esta seja a situação com o fluxo f^0 , pare. Caso contrário, chame o fluxo obtido de f^1 .

Passo 2) Melhora

Para o fluxo f^i , $i \geq 1$, encontre c^i uma solução ótima do CA, com $f = f^i$.

Para $c = c^i$, encontre, se existir, uma árvore de caminhos mais curtos para $q_{rs} > 0$, que não seja o roteamento associado a f^i (a métrica usada é):

$$\alpha_{kl} = \alpha_{lk} = \alpha_j = \frac{\partial t_j (f_j^i, c_j^i)}{\partial t_j} \quad \text{para } \bar{a}(j) = \{k, l\}$$

e cujo caminho mais curto indicado seja estritamente melhor que o associado ao atual roteamento.

Se não existir tal árvore, pare. Caso contrário, altere o fluxo para que os caminhos mais curtos sejam obedecidos. O novo fluxo é f^{i+1} .

Retorne para o passo 2. \square

Fato 3.22 O método proposto em (3.21) converge em um número finito de passos para o ponto (\bar{f}, \bar{c}) , tal que:

(P1) \bar{c} é a solução ótima do (CA), com $f = \bar{f}$;

(P2) \bar{f} é a solução ótima do (FA), com $c = \bar{c}$.

Demonstração: após a normalização, os fluxos f^0 , $i \geq 1$, estão associados biunivocamente a arborescência do grafo G .

Como as arborescências são em número finito e a cada passo a função objetivo do problema é diminuída estritamente, o método para em um número finito de passos.

Analisando as regras de parada, segue a tese. \square

O método (3.21) é essencialmente um método similar ao simplex. Além da garantia de convergência e a aparente não necessidade de (HA), o método apresenta uma grande vantagem sobre o método de dupla projeção, que é a de não implicar na solução do (FA).

Esta vantagem é a substituição da solução do (FA), que exige uma série de iterações, onde, em cada uma, devem ser construídas $\binom{n}{2}$ árvores de Dijkstra e uma busca unidimensional, pelo conjunto de uma direção de descida. Usando a idéia de desvio de fluxo, este último computo exige, no pior caso, $\binom{n}{2}$ árvores de Dijkstra.

É importante notar que em Kleinrock [5], a semente desta idéia está presente, quando ele recomenda desvio total de fluxo. Infelizmente esta idéia aplicada à solução do (FA) pode levar a perda de viabilidade, além de não reduzir o número de desvios de fluxo a um só, como aqui é feito.

Um ponto de aceleração ao algoritmo de desvio de fluxo seria a utilização de árvores prévias para auxiliar a construção das árvores seguintes. Tais idéias foram implementadas por Bezerra [07], mas ainda há uma esperança de melhoria sobre este aspecto.

A facilidade do processo de encontrar a direção de máxima descida sugere naturalmente o caso do algoritmo "steepest decent", apesar de que em geral este método seja criticável quando comparado a métodos de segunda ordem, para a minimização correspondente a (FA). Para especificar completamente o algoritmo, só resta especificar a busca unidimensional. O usual na tradição de Zoutendijk é buscar o mínimo a logo da semireta $(\bar{f} + \lambda \bar{h})$, com a restrição de viabilidade. Como sabemos que $\lim_{f_i \rightarrow \bar{c}_i} \bar{c}_i \bar{c}_i (f_i, \bar{c}_i) = +\infty$, a viabilidade praticamente restringe-se a manter $f_i \geq 0$, $i=1, \dots, m$, o que é automaticamente garantido, com $\lambda \leq 1$. É interessante notar que nos casos rodados sobre os exemplos da rede LARC, obtivemos consistentemente $\lambda=1$. Tal não ocorreu em exemplos gerados aleatoriamente.

Em geral, recomendaríamos o uso da regra de Armijo, baseadas nas experiências relatadas por Polak [8].

Apesar de sua simplicidade teórica, a solução do (FA) tende a consumir ordens de grandeza de tempo a mais que a solução do (CA).

IV - Comentários finais

A utilização do método proposto simplifica a solução do problema de designação de fluxos e capacidades, no sentido de encontrar um ponto estacionário de Kuhn-Tucker, mas a constatação de "concavidade" nas funções $T^*(-,D)$ e $D^*(-,T)$ é clara indicação da existência de mínimos locais. Em particular, quando o fluxo físico restringe-se a uma árvore ($m=n-1$ e grafo conexo), pode-se provar [2] que estamos em um mínimo local.

Assim sendo, maiores resultados orientados para encontrar a solução de PD(T) ou PT(D) ainda não existem afora a recomendação de Gerla [1] de utilizar vários pontos iniciais viáveis e a esperança de obtermos resultados positivos seguindo as idéias de Tuy et alli [9], em particular, no caso de custos lineares e filas M/M/1.

Consideremos entretanto interessante neste trabalho a junção de intuição encontrada nos escritos de Gerla [1] e Kleinrock [5], com o tratamento formal dado a funções valor ótimo dependendo de argumentos do problema, levando a algoritmo mais simples e eficiente, nas linhas de projeção - direções viáveis, como sugerido em Geoffrion.

BIBLIOGRAFIA

- (1) Gerla, M., The design of store-and-forward networks for computer networks. Los Angeles, 1973, 300p, Tese (Doutorado) - University of California.
- (2) Humes Jr., C. Tópico de otimização e redes de computadores. São Paulo, 1988, 109p, Tese (Livre-Docência)-IME-Universidade de São Paulo.
- (3) Lin, J. G. Maximal vectors and multiobjective optimization. Journal of Optimization Theory and Applications, 18(1): 41-64, 1976.
- (4) Lin, J. G. Multiobjective problems: Pareto-optimal solutions by method of proper equality constraints. IEEE Transactions Automatic Control, 21(5): 641-650, 1976.
- (5) Kleinrock, L. Queuing Systems. New York, John Wiley, 1975-76, 2v.
- (6) Geoffrion, A. M. Elements of large-scale mathematical programming. Management Science, 16(11): 652-691, 1970.
- (7) Bezerra, J.R. M. Sobre problemas de otimização de redes de computadores. São Paulo, 1984, 223p. Dissertação (mestrado)-IME-USP.
- (8) Polak, E. Computational methods in optimization. New York, Academic Press, 1971, 329p.
- (9) Tuy, H.; Thieu, T. V.; Thai, NG Q. A conical algorithm for globally minimizing a concave function over a closed convex set. Mathematics of Operations Research, 10(3): 498-514, 1985.