

# AVANÇOS EM ALGORITMOS EVOLUCIONÁRIOS PARA OTIMIZAÇÃO MULTI-OBJETIVO

*Andre Schardong<sup>1</sup>, Slobodan P. Simonovic<sup>2</sup>*

## RESUMO--.

Este artigo apresenta a aplicação de algoritmos evolucionários na análise multi-objetivo para gestão integrada de sistemas de recursos hídricos. As possibilidades de aplicação dos algoritmos evolucionários foram exploradas através de análise multi-objetivo de um sistema de recursos hídricos complexo, o Sistema Cantareira, que abastece parte da Região metropolitana de São Paulo. A análise foi realizada comparando funções objetivos envolvendo: minimização de déficit no atendimento às demandas e minimização do desvio da qualidade da água em relação à Classe de enquadramento no rio Atibaia, a jusante do reservatório Atibainha e Cachoeira. Os resultados apontam que os algoritmos evolucionários multi-objetivo são aptos para aplicação na análise integrada de sistemas de recursos hídricos e representam uma boa alternativa aos métodos denominados “clássicos”, pelas suas características peculiares discutidas no trabalho. Algumas recomendações quanto ao uso dos algoritmos abordados para análise de problemas multi-objetivo são apresentados.

**Palavras-chave:** algoritmos evolucionários multi-objetivo, diferencial evolution, sistemas de suporte a decisões.

## ABSTRACT--.

This paper presents an application of evolutionary algorithms in multi-objective analysis for integrated management of water resources systems. A multi-objective evolutionary algorithm is developed: MoDE-NS-NS and compared to NSGA-II. The possibilities of application of the developed multi-objective evolutionary algorithms are exploited by multi-objective analysis of a complex water resources system, the Cantareira System, responsible for supplying nearly half of the Sao Paulo metro area, which corresponds to approximately 33 m<sup>3</sup>/s. The analysis is done by comparing two pairs of objective functions: minimization of demand shortage versus minimization of the deviation from water quality standards. The results show that the multi-objective evolutionary algorithms are suitable for application to integrated analysis of water resources systems and represent a good alternative to the so called “classical” methods, for its peculiar characteristics discussed on this thesis. The MoDE-NS developed, outperformed NSGA-II results, by obtaining a better coverage of the Pareto fronts especially on the water resources system case study.

**Keywords:** multi-objective evolutionary algorithms, water resources systems, decision support systems.

## 1. INTRODUÇÃO

A disponibilidade de água em quantidade e qualidade insuficientes para atendimento das mais variadas demandas é sem dúvida um dos mais importantes problemas a ser enfrentado no gerenciamento dos recursos hídricos em uma bacia hidrográfica. Muitas vezes é necessário construir reservatórios para regularizar vazões a fim de garantir o abastecimento público, a

<sup>1</sup> Postdoctoral Fellow, Department of Civil and Environmental Engineering, University of Western Ontario, London, Ontario, Canada, N6A 5B9; E-mail: aschardo@uwo.ca

<sup>2</sup> Professor, Department of Civil and Environmental Engineering, University of Western Ontario, London, Ontario, Canada, N6A 5B9; E-mail: simonovic@uwo.ca

irrigação, a geração de energia hidroelétrica, o controle ambiental, o controle da qualidade da água, a recreação, etc. No sistema hídrico, os reservatórios normalmente estão fisicamente interligados ou agem como componentes de um sistema integrado.

Entre as diversas atividades de gestão existem problemas complexos, como a operação de sistemas de recursos hídricos para a alocação de água. Geralmente a alocação da água para atendimento às demandas está condicionada à disponibilidade de água, à restrições operacionais que afetam a entrega da água no curto prazo e conflitos entre os vários usos.

Estes problemas são intrinsecamente de natureza multi-objetivo, sendo necessário considerar, além das restrições operacionais, uma série de outras restrições, seja de natureza, econômica, cultural, tecnológica, entre outros, que podem ser de difícil tratativa nas técnicas de otimização com objetivo único. Segundo Loucks e Beek (2005) e Braga (1987), a abordagem tradicional de benefício/custo, cujos objetivos são convertidos e expressos em uma única unidade de moeda, pode ser extremamente difícil e levar a distorções no conjunto de soluções ótimas.

Nas técnicas de otimização para análise de problemas com objetivo único, os algoritmos de solução buscam um valor ótimo global único dentro do espaço de busca definido pelas restrições do problema. Já as técnicas de análise multi-objetivo geram um conjunto de soluções, e por este motivo o conceito de ótimo global não faz mais sentido. Em geral este conjunto de soluções é conhecido como conjunto de soluções não nominadas, ou frente (ou curva) de Pareto ou ainda soluções não inferiores. Uma solução é dita dominada quando não pode ser melhorada em detrimento de outra solução do conjunto tido como ótimo.

Técnicas tradicionais de análise multi-objetivo utilizam programação matemática para gerar o conjunto de soluções não dominadas. Para isso, existem vários métodos onde o problema multi-objetivo é transformado em um problema de objetivo único e resolvido sucessivamente até que o conjunto de soluções não dominadas seja determinado. Dentre eles destacam-se os métodos de pesos ou ponderações e métodos de restrições que são as técnicas mais comumente utilizadas para análise multi-objetivo e fazem uso de programação matemática, seja ela linear ou não linear. Estes métodos são aqui denominados clássicos para que possam ser diferenciados dos Algoritmos Evolucionários – AE, abordados nesta tese.

Os algoritmos evolucionários surgiram na década de 80 inicialmente com o Algoritmo Genético (AG) bem como sua primeira versão multi-objetivo, Deb (2009). Autores como Simonovic (2009), Deb (2009) e Cunha (2006) destacam algumas características que tornam os algoritmos evolucionários bastante atrativos para análise multi-objetivo em relação aos métodos clássicos, dentre elas:

- trabalham com famílias de soluções, também denominadas populações, e por este motivo são capazes de gerar várias soluções não dominadas em uma única geração;
- são menos susceptíveis à forma ou continuidade da frente de Pareto.
- extremamente flexíveis quanto à formulação do problema, no que diz respeito às funções objetivo e restrições;
- não exigem conhecimento profundo de modelos de otimização, e em geral são de fácil implementação;

Grande atenção vem sendo dada aos algoritmos evolucionários na última década, e com o surgimento de algoritmos alternativos ao AG, muitos pesquisadores tem se dedicado ao desenvolvimento de algoritmos mais eficientes para a análise multi-objetivo. Dentre eles estão o DE (*Differential Evolution*) cujas versões para análise multi-objetivo são foco de estudo desta tese, bem como sua aplicação em análise multi-objetivo de sistemas de recursos hídricos.

O algoritmo evolucionário para análise multi-objetivo (AEM) desenvolvido, denominado MoDE-NS: *Multi-objective Differential Evolution*, e por sua vez comparado com uma versão multi-objetivo do AG, denominada *Non-dominated Sorting Genetic Algorithm - NSGA-II*, para efeitos de

validação. Os dois algoritmos foram sistematizados em um Sistema de Otimização Multi-objetivo composto por uma interface gráfica e uma biblioteca de algoritmos. O NSGA-II foi traduzido para a mesma linguagem de programação utilizada no desenvolvimento do Sistema e neste incorporado, porém todas as suas características originais foram preservadas.

## 2. METODOLOGIA

O *Differential Evolution* (DE) foi proposto por Price e Storn (1997) e é um dos algoritmos evolucionários mais recentes para solução de problemas de otimização com valores reais. O DE utiliza um operador de mutação simples baseado nas diferenças entre os pares de solução (também chamado de vetores) com o objetivo de encontrar a direção de busca com base na distribuição de soluções na população corrente.

Diferentemente do Algoritmo Genético (AG), que depende fortemente do operador de cruzamento, o DE utiliza a mutação como o mecanismo principal de busca, e a seleção para indicar a direção dentro da região viável do espaço de decisão. O DE é baseado em populações e utiliza  $N_p$  indivíduos e  $D$  vetores variáveis para cada geração.

A ideia básica do DE é um esquema para a geração do chamado vetor de testes. O DE gera este novo vetor a partir de dois membros da população. Se o vetor de testes possui um valor de função objetivo superior a um vetor predeterminado da população, este substituirá o vetor ao qual esta sendo comparado. Além disso, a cada geração o vetor com a melhor função objetivo é sempre armazenado para manter o registro do progresso ao longo do processo de otimização. Além disso, algumas estratégias de solução do DE fazem uso da melhor solução encontrada. Price et al. (2005) destacam que a utilização da informação da distância e direção da população para gerar derivações randômicas resulta em um esquema adaptativo com propriedades excelentes de convergência.

A implementação original do DE mantém um par de vetores da população, ambos contendo  $N_p$  indivíduos e dimensão  $D$  (número de variáveis), com valores de variáveis em representação real. A população corrente, representada por  $P_{x,t}$  é composta por vetores,  $X_{i,t}$ , equação (2.1),  $P_{u,t}$  representa a população de teste que é composto por vetores de teste, representados por  $U_{i,t}$ , equação (2.2).

$$P_{x,t} = (X_{i,t}), \quad i = 0, 1, \dots, N_p - 1, \quad t = 0, 1, \dots, gmax \quad (2.1)$$

$$X_{i,t} = (x_{j,i,t}), \quad j = 0, 1, \dots, D - 1$$

$$P_{u,t} = (U_{i,t}), \quad i = 0, 1, \dots, N_p - 1, \quad t = 0, 1, \dots, gmax \quad (2.2)$$

$$U_{i,t} = (x_{j,i,t}), \quad j = 0, 1, \dots, D - 1,$$

Onde  $x_{j,i,t}$  é a variável de decisão

A população inicial é gerada aleatoriamente a partir dos limites mínimos e máximos de cada variável de decisão (caso não exista informação do problema disponível), conforme equação (2.3).

$$x_j = \text{rand}(0,1) \times (b_{j,U} - b_{j,L}) + b_{j,L}, \quad j = 0, 1, \dots, D - 1 \quad (2.3)$$

Onde  $x_j$  é a variável de decisão e  $b_{j,L}$  o limite inferior da variável  $j$  e  $b_{j,U}$  o limite superior da variável  $j$ .

No DE a mutação é utilizada para criar uma população de  $N_p$  vetores de teste. A formulação original utiliza três vetores escolhidos aleatoriamente para criar o vetor mutante  $V_{i,t}$ , como descrito na equação (2.4). O fator  $F$  utilizado é um número real, geralmente entre 0 e 1 (Vassan e Simonovic, 2008) e determina a evolução da população ao longo das gerações. Os índices dos vetores  $r_0$ ,  $r_1$ ,  $r_2$  são escolhidos aleatoriamente, da posição 0 à  $N_p-1$ , a cada geração, e são diferentes entre si e do vetor atual  $i$ .

$$V_{i,t} = X_{r_0,t} + F(X_{r_1,t} - X_{r_2,t}), \quad j = 0,1, \dots, D - 1, \quad t = 0,1, \dots, g_{\max} \quad (2.4)$$

Após a mutação, um cruzamento uniforme é aplicado aos vetores de teste gerados na mutação, como descrito na equação (2.5). A probabilidade de cruzamento CR determina o número ou fração das variáveis utilizadas para o processo. Para determinar se uma variável será considerada para o cruzamento, um número randômico é gerado entre 0 e 1, e comparado à probabilidade de cruzamento CR. Se CR é maior que o número randômico gerado, a variável  $v_{j,i,t}$  é utilizada para compor o vetor de testes, caso contrário, a variável  $x_{j,i,t}$  é utilizada. Além disso, a variável jrand, selecionado aleatoriamente para comparação, é excluído do vetor de testes para garantir que a variável  $x_{j,i,t}$  não seja duplicada.

$$U_{i,t} = u_{j,i,t} = \begin{cases} v_{j,i,t} & \text{se } \text{rand}(0,1) \leq Cr \text{ ou } j = \text{jrand} \\ x_{j,i,t} & \text{caso contrário} \end{cases} \quad (2.5)$$

O processo de seleção consiste em verificar se o vetor  $U_{i,g}$  tem um valor de função objetivo melhor que o vetor  $X_{i,g}$  com o qual é comparado, equação (2.6).

$$X_{i,t} = \begin{cases} U_{i,t} & \text{se } f(U_{i,t}) \leq f(X_{i,t}) \\ X_{i,t} & \text{caso contrário} \end{cases} \quad (2.6)$$

A convenção geral usada por diferentes variantes do DE é  $DE/\alpha/\beta/\gamma$ , onde  $\alpha$  representa o vetor a ser perturbado (selecionado aleatoriamente),  $\beta$  o número de vetores considerados para a mutação e  $\gamma$  o tipo de cruzamento utilizado (pode ser exp: exponencial ou bin: binomial).

A variante descrita acima é denominada DE/rand/1/bin, também conhecida como DE clássico, e é a estratégia original proposta por Price e Storn (1997). Os mesmos autores propuseram outras estratégias, que combinam de forma diferente os vetores para mutação.

Entretanto, como observado por Vassan e Simonovic (2008) e Schardong et al. (2009) e Schardong (2011), a estratégia DE/rand/1/bin parece sempre obter os melhores resultados para a maioria dos problemas de objetivo único.

No algoritmo multi-objectivo do DE (MoDE-NS) desenvolvido, foram incluídos os operadores considerados mais importantes para o bom desempenho (estado da arte) de um AEM baseado no DE (*Diferencial Evolution*), além obviamente das estratégias básicas de otimização. Os operadores incluídos foram: mecanismo de parâmetros variáveis (também chamado de “self-adaptive”), mutação pós-geração e um operador adicional de elitismo de seleção. Estes aspectos são discutidos a seguir.

Para o algoritmo MoDE-NS foram implementadas as principais estratégias de solução existentes para geração da população de descendentes  $Q_t$  a partir da solução pai  $P_t$ . A versão multi-objectivo possui algumas particularidades comparada à versão com objetivo único, que são referentes à escolha do vetor  $\alpha$  a ser combinado das estratégias  $DE/\alpha/\beta/\gamma$ , e o processo de seleção do vetor mutante gerados. No MoDE-NS das estratégias incorporadas o vetor  $\alpha$  pode ser rand, best, rand-to-best e current-to-best. A Tabela 2.1 apresenta a forma de cálculo do vetor mutante  $V_{i,t}$  das estratégias citadas, conforme Chakraborty (2008).

Tabela 2.1 – Estratégias de solução do MoDE-NS

Estratégia	Geração do Vetor de Testes $V_{i,t}$
------------	--------------------------------------

Estratégia	Geração do Vetor de Testes $V_{i,t}$
DE/rand/ $\beta/\gamma$	$V_{i,t} = X_{r0,t} + F \sum_{\beta=1}^2 (X_{r1+2.(\beta-1),t} - X_{r2+2.(\beta-1),t})$
DE/best/ $\beta/\gamma$	$V_{i,t} = X_{best,t} + F \sum_{\beta=1}^2 (X_{r1+2.(\beta-1),t} - X_{r2+2.(\beta-1),t})$
DE/rand-to-best/ $\beta/\gamma$	$V_{i,t} = X_{r0,t} + F \sum_{\beta=1}^2 (X_{rbest,t} - X_{r1+2.(\beta-1),t})$
DE/current-to-rand/ $\beta/\gamma$	$V_{i,t} = X_{i,t} + F(X_{r1,t} - X_{r2,t}) + K(X_{r3,g} - X_{i,t})$

No MoDE-NS os critérios utilizados para seleção dos indivíduos variam da seguinte maneira, dependendo da escolha da estratégia:

Estratégias com o tipo DE/rand: um indivíduo é escolhido aleatoriamente da população  $P_t$  para ser utilizado na geração do vetor de teste.

Estratégias do tipo DE/best: em análise multi-objetivo não existe o conceito de melhor global. Desta forma, para este tipo de estratégia é adotado o seguinte critério: dois indivíduos com nível 1 de classificação de não dominância são aleatoriamente escolhidos, e o indivíduo dominante é então escolhido como  $X_{best,t}$ .

Estratégias do tipo DE/current-to-rand: nesta estratégia o vetor utilizado para a geração de  $V_{i,t}$  é o próprio  $X_{i,t}$ , independente do seu nível de dominância ou status na população  $P_t$ , ou seja, todos os indivíduos são utilizados para formar a geração da população descendente.

Os valores de  $\beta$  podem ser 1 ou 2, para  $\beta = 1$ , teremos a combinação de dois vetores  $X_{r1,t} - X_{r2,t}$  e para  $\beta = 2$ ,  $X_{r3,t} - X_{r4,t}$ .

Já o valor de  $\gamma$ , que indica cruzamento binomial (bin) ou exponencial (exp). A escolha entre um e outro não é muito importante no processo, como os próprios autores do DE já haviam destacado, sendo que exponencial é similar ao cruzamento em dois pontos do AG e o binomial similar ao cruzamento uniforme. Esta etapa ocorre após a geração do vetor mutante  $V_{i,t}$ , gerando o chamado vetor de teste  $U_{i,t}$ , conforme equação (2.7).

$$U_{i,t} = u_{j,i,t} = \begin{cases} v_{j,i,t} & \text{if } rand(0,1) \leq Cr \text{ ou } j = jrand \\ x_{j,i,t} & \text{caso contrário} \end{cases} \quad (2.7)$$

A última etapa para a geração do vetor descendente é verificar se o valor da FO do vetor de testes  $U_{i,t}$  é melhor que do vetor original do  $X_{i,t}$ ,  $f(U_{i,t}) \leq f(X_{i,t})$ . Porém, como se trata de análise multi-objetivo, não é possível fazer essa comparação de forma direta. Desta forma, no MoDE-NS, o vetor  $U_{i,t}$  é aceito para fazer parte da nova geração  $Q_t$ .

Entretanto, para transportar este critério de seleção do DE para o MoDE-NS, foi incluído um parâmetro (definido a critério do usuário) com o qual o algoritmo passa a fazer a comparação dos dois vetores, e só aceitará o vetor de testes  $U_{i,t}$  se este dominar  $X_{i,t}$ , equação (2.8). Na prática este mecanismo não se mostrou eficiente em termos de resultados, embora não tivesse impacto negativo no tempo de processamento. Este mecanismo é denominado “Elitismo de Seleção”.

$$X_{i,t} = \begin{cases} U_{i,t} & \text{se } U_{i,g} \preceq X_{i,t} \\ X_{i,t} & \text{caso contrário} \end{cases}, \text{ onde } X_{i,t} \in Q_i \quad (2.8)$$

Um segundo mecanismo introduzido foi a variação dos Parâmetros de controle F e CR, ao longo do processo de otimização. Estes podem ser definidos como fixos; variáveis com o número de

gerações entre os valores mínimos e máximos definidos; ou aleatórios dentro de uma faixa. Na prática a variação linear dos parâmetros entre um limite inferior e superior apresentou os melhores resultados.

### 3. RESULTADOS E DISCUSSÃO

Os algoritmos também são aplicados a um problema relacionado à área de recursos hídricos, o Sistema Cantareira, responsável por parte do atendimento da demanda de água da Região Metropolitana da cidade de São Paulo (RMSP).

A Região Metropolitana de São Paulo – RMSP é abastecida por 6 (seis) grandes sistemas: Cantareira, Guarapiranga, Alto Tietê, Rio Grande, Rio Claro e Cotia. O sistema mais importante é o Cantareira, que fornece aproximadamente 33 m<sup>3</sup>/s para a RMSP.

O sistema Cantareira deriva água da bacia dos Rios Piracicaba, Capivari e Jundiá (PCJ) para a bacia do Rio Tietê por uma série de Reservatórios, canais e túneis. O sistema Cantareira é composto por 5 reservatórios principais, sendo que quatro deles: Jaguari, Jacareí, Cachoeira e Atibainha estão localizados na bacia do PCJ (Figura 3.1) e o reservatório Paiva Castro pertence à bacia do Rio Tietê. Os dados operacionais, valores de demandas (tanto para a bacia do Rio Piracicaba quanto para a RMSP), vazões mínimas e máximas (vazões de restrição) a jusante dos reservatórios, foram compilados de Castro (2003), ANA (2004), DAEE (2009) e Sabesp (2009a e 2009b). O resumo compilado é apresentado na Tabela 3.1. A série de vazões naturais utilizada foi obtida de Sabesp (2009b).

Tabela 3.1 – Resumo dos dados Operacionais do Sistema Cantareira

Reservatório	Níveis operacionais (m)		Volumes (x10e6 m <sup>3</sup> )		
	Min	Max	Min	Max	Útil
Jaguari-Jacareí	820,80	844,00	239,45	1047,49	808,04
Cachoeira	811,72	821,78	46,92	115,71	68,79
Atibainha	781,88	786,86	199,20	295,52	96,32
Paiva Castro	743,80	745,61	25,52	33,05	7,53

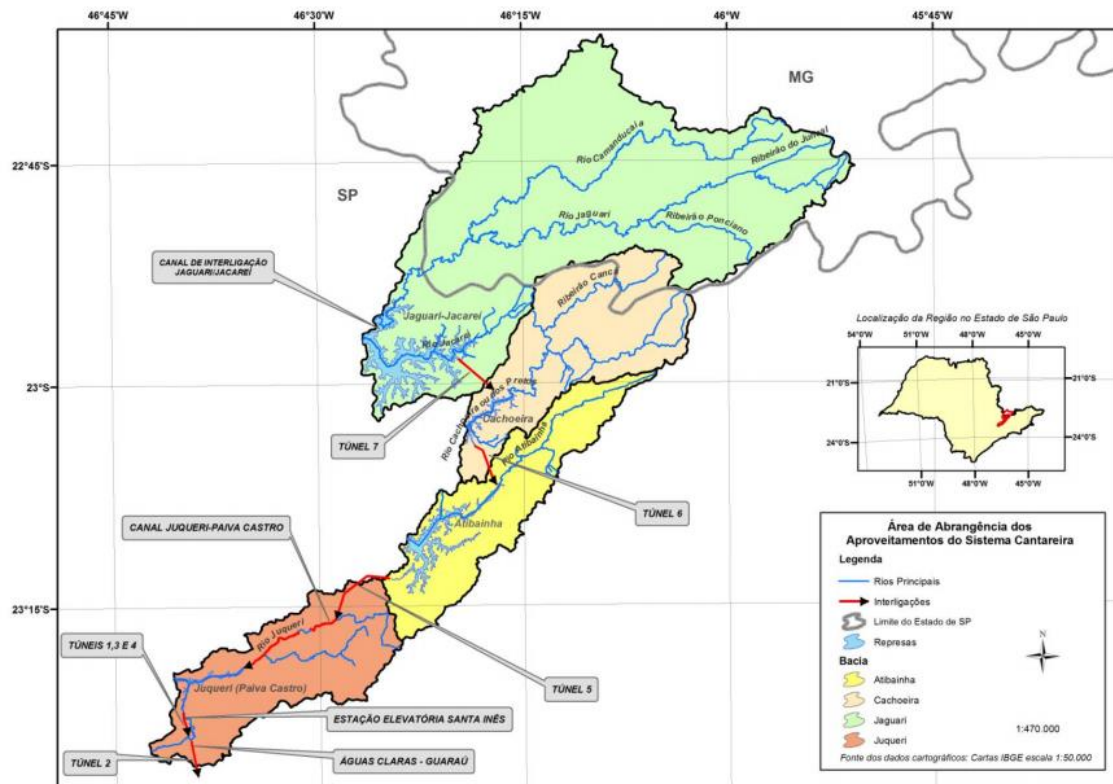


Figura 3.1 – Localização e Componentes Principais do Sistema Cantareira. Fonte: Sabesp (2009a)

Os primeiros reservatórios do sistema, conforme Figura 3.1, são o Jaguarí Jacaréi que conectados por um canal podem ser tratados como um único reservatório no modelo. Estes são conectados ao reservatório Cachoeira pelo Túnel 7. O Túnel 6 conecta o reservatório Cachoeira ao Atibainha que por sua vez é conectado ao Paiva Castro pelo Túnel 5, onde ocorre a transferência entre as bacias do PCJ e Alto Tietê. Os três túneis citados transferem a água por gravidade. Do reservatório Paiva Castro a água é conduzida por gravidade até a estação elevatória Santa Inês (ESI). Após ser elevada por um conjunto de bombas a água passa por um pequeno reservatório para fins de regulação em caso de emergências (ex: falta de energia elétrica) e finalmente conduzida à estação de tratamento de água bruta (ETA) Guaraú. Por sua pequena capacidade de armazenamento e regulação (< 1 hm<sup>3</sup>), o reservatório Águas Claras não será considerado nesta análise, que será realizado em período mensal.

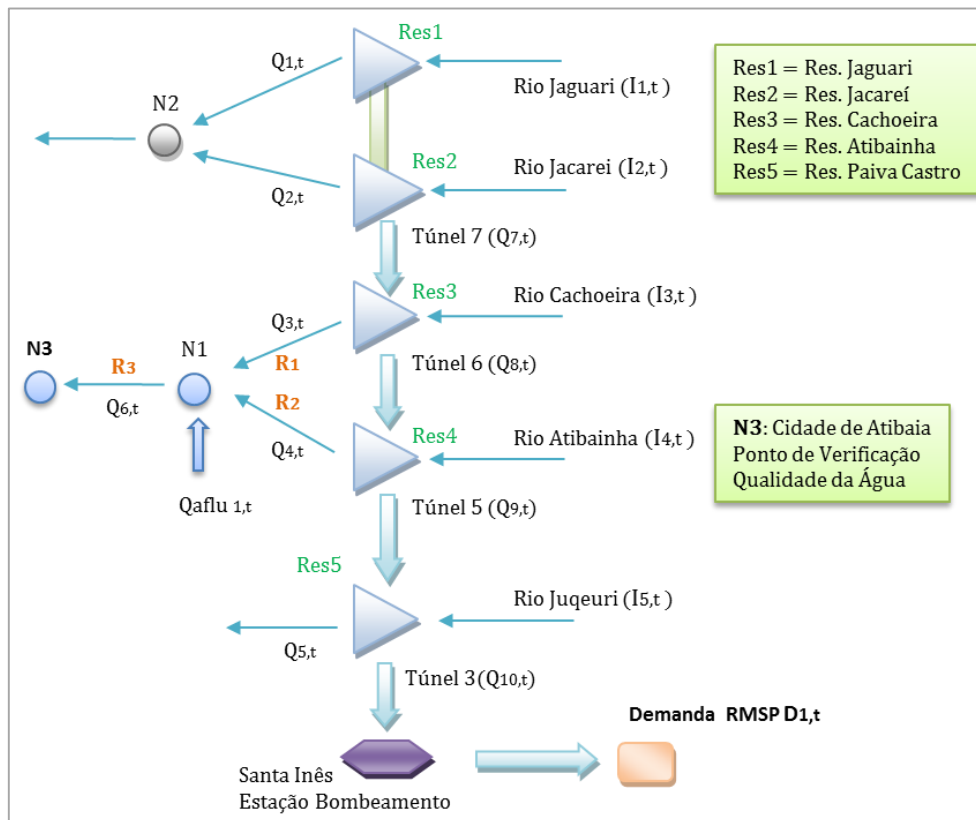


Figura 3.2 – Representação Esquemática do Sistema Cantareira

Para esta análise integrada são considerados dois objetivos:  $f_1$  - atendimento às demandas para RMSP e bacia do PCJ;  $f_2$ . Enquadramento do rio Atibaia à Classe 2 no ponto de controle N3 (conforme Figura 3.2) considerando a DBO (Demanda Bioquímica de Oxigênio). Na Figura 3.2 é apresentado um esquema do Sistema Cantareira com a indicação das variáveis consideradas nas simulações. As funções objetivo são descritas detalhadamente a seguir, bem como as restrições de balanço e limites das variáveis do sistema.

- Função Objetivo  $f_1$  - Minimização do Déficit de atendimento à demanda: A função objetivo que calcula o déficit do atendimento às demandas é apresentada na equação (3.1).

$$\min f_1 = \sum_{t=1}^m (D_{1,t} - Q_{10,t})^2 + (D_{2,t} - [Q_{1,t} + Q_{2,t} + Q_{3,t} + Q_{4,t}])^2 \quad (3.1)$$

Onde  $D_{1,t}$  é a demanda para RMSP,  $Q_{10,t}$  é a vazão de bombeamento na estação elevatória Santa Inês,  $D_{2,t}$  a demanda para bacia do PCJ.  $Q_{1,t}$ ,  $Q_{2,t}$ ,  $Q_{3,t}$  e  $Q_{4,t}$  a vazão a jusante dos reservatórios Jaguari/Jacareí, Cachoeira, Atibainha, respectivamente, adotada como 5 m<sup>3</sup>/s. Este valor de demanda pode variar mensalmente de acordo com o entendimento feito entre Sabesp e o Comitê de Bacia do PCJ.

- Função  $f_2$ . Minimização do desvio do enquadramento do rio Atibaia à Classe 2 no ponto de controle N3: a função objetivo para o cálculo do desvio do valor de DBO em relação à classe de enquadramento do rio Atibaia é calculada como apresentado na equação (3.2).

$$\min f_2 = \sum_{t=1}^m (DBO - f_{DBO}(Q_{3,t}, Q_{4,t} \text{ e } Q_{6,t}))^2 \quad (3.2)$$

Onde  $f_{DBO}$  é o valor da concentração da DBO em mg/L no nó N3 (Cidade de Atibaia).



Este trecho do Rio Atibaia analisado é classificado como Classe 2 (Cobrape 2010). Para esta classe o padrão de qualidade, o valor máximo permitido da DBO é de 5,0 mg/L.

Para o cálculo da qualidade da água foi considerada apenas a DBO (L) remanescente utilizando as equações exponenciais propostas por Chapra (1997).

O decaimento da DBO calculada nos trechos R1, R2 e R3 (Figura 3.1) para cada intervalo simulado e o balanço de massa é calculado em N1 e N3. Os coeficientes utilizados nas equações de qualidade da água são apresentados na Tabela 3.2, e foram obtidos do Plano das Bacias Hidrográficas do PCJ, Cobrape (2010). Outros dados como vazão e concentração de lançamento e captações foram também obtidos de Cobrape (2010), e são apresentados na Tabela 3.3. Por se tratar de um modelo simplificado, as captações e lançamentos nos trechos R1 e R2 são consideradas no balanço do nó N1 e do trecho R3, no nó N3.

Tabela 3.2. Coeficientes do Modelo de Qualidade

Trecho	Comp. (km)	a	b	C	d	Kd	Ks
R1	35,27	0,35	0,28	0,41	0,44	1,05	0,25
R2	26,30	0,34	0,27	0,41	0,45	1,05	0,25
R3	24,40	0,83	0,27	0,28	0,49	1,05	0,25

Tabela 3.3. Vazões de Captação e Lançamento

Trecho	Captações (m <sup>3</sup> /s)	Lançamentos	
		Vazão (m <sup>3</sup> /s)	DBO (mg/L)
R1	0,13	0,07	129,20
R2	0,08	0,05	155,82
R3	0,90	0,30	149,77

A análise multi-objetivo foi realizada considerando um período de 24 meses, correspondente a dois anos de dados de vazão natural no período de 1952 a 1954, cuja média 33,95 m<sup>3</sup>/s é inferior à média histórica de aproximadamente 44,3 m<sup>3</sup>/s.

Para a análise foi considerada a demanda para RMSF de 33 m<sup>3</sup>/s. O tamanho da população igual a 500 e número de gerações máximo de 50.000, e foram executadas um total de 10 simulações completas.

É verificada a relação entre o déficit da demanda para a RMSF (f1) e o impacto da qualidade da água no rio Atibaia à jusante dos reservatórios Cachoeira e Atibainha (f2). O modelo de qualidade empregado mede o desvio do valor da DBO em relação à classe 2 de enquadramento no ponto de comparação no ponto N3 (cidade de Atibaia), conforme Figura 3.2.

No gráfico da Figura 3.3 é apresentada a comparação do conjunto de soluções não dominadas de cada um dos algoritmos para a simulação considerando f1 x f2. Analisando os conjuntos de soluções não dominadas do gráfico de Figura 3.3, é possível observar, pelo formato da curva, que permitindo um déficit ao atendimento às demandas seria possível melhorar

significativamente o valor da função objetivo  $f_2$ , que mede o desvio da DBO em relação à classe 2. Isto ocorre por que o gradiente da curva de soluções não dominadas é elevado para déficits pequenos no atendimento às demandas. Porém à medida que os déficits ao atendimento à demanda aumentam, a taxa de diminuição da função  $f_2$  cai significativamente. A análise foi realizada considerando um valor constante e desfavorável para a DBO da vazão efluente aos reservatórios Atibainha e Cachoeira (5 mg/L para todos os meses). Este cenário foi assim configurado para evidenciar as relações de troca entre o déficit de atendimento às demandas e o impacto na qualidade da água a jusante. No próximo item são apresentadas duas simulações com valores de DBO mais baixos (3 e 1 mg/L) da vazão efluente aos reservatórios. É possível verificar que as curvas de troca (conjuntos de soluções não dominadas) mantem as características da curva apresentada nesta simulação, na Figura 3.3. O mesmo deve acontecer ao se empregar um modelo de qualidade mais detalhado, como o Qual2e.




Figura 3.3 – Comparação das Soluções não dominadas  $f_1$  x  $f_2$

Na Tabela 3.4 são apresentados os valores das soluções de compromisso utilizando  $\alpha(f_1) = 0,5$  e  $\alpha(f_2) = 0,5$  com o qual se obtém um déficit de atendimento à demanda da RMSD de cerca de 2000 [m<sup>3</sup>/s]<sup>2</sup> que equivale à aproximadamente 1,8 m<sup>3</sup>/s de déficit médio mensal.

Tabela 3.4 – Soluções de compromisso para  $\alpha(f_1) = 0,5$  e  $\alpha(f_2) = 0,5$

Algoritmo	$f_1 - [m^3/s]^2$	$f_2 - [mg/L]^2$
MoDE-NS	2314,81	106,67
NSGA-II	1998,19	123,66

#### 4. CONSIDERAÇÕES FINAIS

Este artigo estudou a aplicação de algoritmos evolucionários na análise multi-objetivo para gestão de sistemas de recursos hídricos. São empregados três algoritmos multi-objetivo derivados do Differential Evolution (MoDE-NS) e Algoritmo Genético (NSGA-II). Os resultados da aplicação ao estudo de caso, mostraram que os algoritmos MoDE-NS desenvolvido é mais eficiente em comparação ao NSGA-II. No desenvolvimento do MoDE-NS foi utilizada a estrutura de população e geração dos descendentes derivada do NSGA-II. Esta estrutura se mostrou bastante eficiente.. É importante ressaltar que no MoDE-NS a única estratégia capaz de produzir bons resultados quando aplicado em problemas mais complexos é a DE/current-to-rand. O MoDE-NS e o NSGA-II representam o estado da arte em AEM disponíveis, e sua aplicação é recomendada para análise multi-objetivo de sistemas de recursos hídricos, desde que o problema não tenha um grande número de variáveis e/ou restrições.

A limitação dos AEM em lidar um grande número de variáveis e restrições pode ser superada com a integração destes aos algoritmos de rede fluxo extremamente eficientes como o Out-of-Kilter do AcquaNet ou Relax IV do ModSim.

Os AEM são sem dúvida uma alternativa importante e interessante aos métodos aqui denominados “clássicos”, porém é necessário considerar suas limitações, principalmente quanto ao número de variáveis e restrições. Desta forma, problemas menores podem ser facilmente resolvidos com a utilização dos AEM aqui estudados. O caráter flexível dos algoritmos evolucionários multi-objetivo abordados neste artigo.

Com base nas dificuldades encontradas durante o desenvolvimento da tese e na aplicação dos algoritmos aos problemas estudados, algumas recomendações para pesquisas futuras, principalmente relacionadas aos AEM, são relacionadas:

- Estudar o impacto de outros tipos de operadores de diversidade, uma vez que nesta tese foi utilizado apenas o *Crowding Distance*.
- Estudar outros esquemas “adaptivos” para a variação dos parâmetros ao longo das gerações, como os discutidos em Coello Coello (2010);
- Estender a análise de sensibilidade a outros tipos de problemas reais e verificar o desempenho dos algoritmos com os valores aqui propostos;
- O aperfeiçoamento contínuo dos AEM utilizados se faz necessário, uma vez que estes ainda são alvo de intensas pesquisas, e é natural que métodos mais eficientes sejam propostos.
- Estudar e explorar de forma mais detalhada a questão da influência das restrições no AEM.

#### 5. REFERÊNCIAS

ANA. AGÊNCIA NACIONAL DE ÁGUAS. Nota Técnica nº 353/SOC - Restrições de usos de recursos hídricos em função das regras de operação do Sistema Cantareira. Brasília: ANA, 2004.

BALTAR, A. M. 2007 Use of Multi-Objective Particle Swarm Optimization in Water Resource Management. 2007. 263 p. Tese (Doutorado) - Department of Civil and Environmental Engineering - Colorado State University, Fort Collins, Colorado.

BRAGA, B. P. F. Técnicas de otimização e simulação aplicadas em sistemas de recursos hídricos. In: BARTH, F. T. et al. Modelos Para Gerenciamento de Recursos Hídricos. São Paulo: ABRH/Nobel, 1987. Cap. 5, p. 427-518.

CASTRO, H. L. Avaliação da disponibilidade hídrica para abastecimento público da Região Metropolitana de São Paulo com o uso de um SSD - Sistema de Suporte a Decisões. 169p. Dissertação (Mestrado). Universidade de São Paulo, São Paulo, 2003.

- CHAKRABORTY, U. K. (ed.) *Advances in Differential Evolution*, Berlin: Springer-Verlag, 2008. 340 p. (Studies in Computational Intelligence, Vol. 143).
- CHAPRA, S. C. *Surface Water Quality Modeling*. USA: McGraw-Hill. 844p. 1997.
- COBRAPE - Companhia Brasileira de Projetos e Empreendimento. *Plano das Bacias Hidrográficas dos Rios Piracicaba, Capivari e Jundiáí 2010 a 2020*. São Paulo. 2010.
- COELLO COELLO C. A.; DHAENENS, C.; JOURDAN, L. (Ed.) *Advances in Multi-Objective Nature Inspired Computing*, 1st ed. Berlin: Springer-Verlag, 200 p. (Studies in Computational Intelligence, Vol. 272). 2010.
- CUNHA C. B. *Contribuição à modelagem de problemas em logística e transportes*. 2006. 315 p. Tese (Livre-Docência) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Transportes. São Paula, 2006.
- DAEE, Secretaria De Estado De Saneamento E Energia Departamento De Águas E Energia Elétrica Diretoria De Procedimentos De Outorga E Fiscalização. *Nota Técnica DAEE/DPO – Sistema Cantareira - Recomendações para manutenção de volumes de espera nos reservatórios dos aproveitamentos do Sistema Cantareira*, 2009.
- DEB, K. *Multi-Objective Optimization Using Evolucionary Algorithms*, United Kingdom: John Wiley & Sons. 2009. 515p.
- LOUCKS, D.P.; BEEK, E. van, *Water resources systems planning and management. An introduction to methods, models and applications*, Studies and Reports in Hydrology. Paris: UNESCO Publishing, 2005.
- PRICE, K. V. e STORN, R. M. *Differential evolution - A simple evolution strategy for fast optimization*. *Dr. Dobb's Journal*. 22, 18-24. 1997
- PRICE, K. V., STORN, R. M. e LAMPINEN, J. A. *Differential evolution: A practical approach to global optimization*. Berlin: Springer. 2005.
- VASAN A. e SIMONOVIC S. P. (2008). *Optimization Using Differential Evolution*. Water Resources Research Report no. 060, Facility for Intelligent Decision Support, Department of Civil and Environmental Engineering, London, Ontario, Canada, 38 pp.
- SCHARDONG, A. et al. *Comparação De Algoritmos Evolucionários Na Calibração De Modelo Chuva-Vazão - Smap*. In: XVIII Simpósio Brasileiro de Recursos Hídricos, 2009, Campo Grande - MS. XVIII Simpósio Brasileiro de Recursos Hídricos. PORTO ALEGRE : ABRH, 2009.
- SCHARDONG, A. *Aplicação de algoritmos evolucionários à gestão integrada de sistemas de recursos hídricos*. Tese de Doutorado, Universidade de São Paulo, 2011.
- SIMONOVIC, S. P. *Managing Water Resources - Methods and Tools for a Systems Approach*. London: UNESCO Publishing. 2009. 640 p.
- SABESP – Companhia de Saneamento Básico do Estado de São Paulo. *Estudos De Cheias Para Avaliação Dos Volumes De Espera Dos Aproveitamentos Do Sistema Cantareira, Relatório Final*, 2009.
- \_\_\_\_\_, *Reconstituição De Vazões Naturais Do Sistema Cantareira, Relatório Final*, 2009.

## 6. AGRADECIMENTOS

Os autores agradecem ao CNPq (Conselho Nacional de Pesquisa e Desenvolvimento) e *Natural Sciences and Engineering Research Council of Canada* pelo suporte financeiro na realização da pesquisa, bem como à Sabesp – Companhia de Saneamento Básico do Estado de São Paulo pelo fornecimento dos dados, em especial aos Engenheiros Nilzo René Fumes e Carlos Toshio Wada.