

ALGORITMO GENÉTICO PARA O PROBLEMA DO DESPACHO ECONÔMICO DE ENERGIA ELÉTRICA COM INCERTEZAS

Rômulo Neves Martins

Universidade Federal de Viçosa - Campus Florestal
Rodovia LMG 818, km 6, 35690-000 - Florestal - MG
romulo.martins@ufv.br

Marcus Henrique Soares Mendes

Universidade Federal de Viçosa - Campus Florestal
Rodovia LMG 818, km 6, 35690-000 - Florestal - MG
marcus.mendes@ufv.br

RESUMO

A presença das incertezas pode alterar o valor da função objetivo a ser otimizada bem como os valores das funções de restrição, assim as soluções encontradas podem se tornar inviáveis e/ou com custos indesejáveis. Este trabalho propõe uma versão Robusta do Problema do Despacho Econômico de Energia Elétrica (RPDEEE), onde são consideradas incertezas paramétricas. Implementou-se três técnicas para lidar com as incertezas no RPDEEE. As três técnicas foram incorporadas em um algoritmo genético a fim de resolver o RPDEEE. Inicialmente, mostrou-se que soluções que desconsideram as incertezas (soluções nominais), quando submetidas às incertezas (solução nominal perturbada), estão suscetíveis à deterioração significativa em seus valores de função objetivo. No experimento, verificou-se que as soluções robustas, obtidas a partir das técnicas propostas, têm valores da função objetivo melhores que os das soluções nominais perturbadas. O aluno redigiu o texto, modelou o problema, realizou as implementações e os experimentos.

PALAVRAS CHAVE. Otimização Robusta, Incerteza, Computação Evolutiva.

Área Principal: MH - Meta-heurísticas, EN - PO na Área de Energia

ABSTRACT

The presence of uncertainties can change the value of the objective function to be optimized as well as the values of the constraint functions, therefore the achieved solutions can become infeasible and/or with undesirable costs. This paper proposes a robust version of the Economic Dispatch Problem (EDP), where parametric uncertainties are considered. Three techniques were implemented to deal with the uncertainties in the problem. The three techniques were incorporated in a genetic algorithm in order to solve the EDP. Initially, it was shown that solutions that consider the uncertainties (nominal solutions), when subjected to the uncertainties (disturbed nominal solutions), are susceptible to significant deterioration in their objective values. In the experiment, it was verified that the robust solutions, obtained from the proposed techniques, have better objective values than the disturbed nominal solutions objective values. The student wrote the text, built the mathematical model, implemented the code and performed the experiments.

KEYWORDS. Robust Optimization. Uncertainty. Evolutionary Computation.

Main Area: MH - Metaheuristics, EN - OR in the Energy Area

Artigo submetido ao XLVIII Simpósio Brasileiro de Pesquisa Operacional (SBPO) - Vitória - ES, 2016, na modalidade de Prêmio de Iniciação Científica (PIC).

1. Introdução

O Problema do Despacho Econômico de Energia Elétrica (PDEEE) foi criado por engenheiros, por volta de 1920, em busca de uma divisão adequada de carga e alocação econômica das unidades geradoras [Jeronymo, 2013]. Com o passar do tempo, foram inseridas características ao problema, de forma a torná-lo mais realista, como por exemplo: o efeito do ponto de válvula. Como qualquer problema real, o PDEEE está sujeito às incertezas, como: alterações de pressão e temperatura, manutenção mal feita, qualidade do combustível, limites de precisão do equipamento, entre outras. Assim, neste trabalho, propõe-se considerar as incertezas no PDEEE. Tal versão do problema é denominada: versão Robusta do PDEEE (RPDEEE), que considera a imprecisão na potência produzida pelas unidades geradoras; e possui uma função objetivo multidimensional, multimodal e descontínua.

Como esse problema tem alta complexidade foi proposto um Algoritmo Genético (AG) robusto com codificação real para resolvê-lo. A meta-heurística algoritmos genéticos foi escolhida por ser poderosa para resolver problemas com muitas dimensões, flexível para tratar incertezas e possui uma boa velocidade de convergência [Michalewicz, 2013]. A principal contribuição do presente trabalho é desenvolver um AG acoplado com técnicas para lidar com incertezas a fim de solucionar o RPDEEE na pior atuação das incertezas.

A Seção 2 apresenta o PDEEE; Na Seção 3, apresentam-se os tipos de incertezas; na Seção 4, são apresentados os conceitos relacionados à robustez; Na Seção 5, apresentam-se os fundamentos da meta-heurística algoritmos genéticos; Na Seção 6, define-se o RPDEEE; Na Seção 7, descrevem-se a três técnicas usadas para o tratamento de incertezas e o algoritmo desenvolvido; Na Seção 8, é apresentado o experimento realizado e sua análise; e por fim, as conclusões são apresentadas na Seção 9.

2. Problema do Despacho Econômico de Energia Elétrica (PDEEE)

O PDEEE constitui-se de uma usina de geração de energia termoelétrica, cujo objetivo é encontrar uma distribuição de potência ótima dada uma função de custo que deve ser minimizada. A usina dispõe de Unidades Geradoras (UGs), que produzem energia elétrica por meio da queima de combustível. Cada UG possui restrições referentes às potências mínimas e máximas que podem produzir, e uma função de custo pela queima do combustível. O somatório das potências produzidas pelas UGs devem atender a uma determinada demanda a cada intervalo de tempo (por exemplo, algumas horas); e o custo total é o somatório dos custos de produção de cada UG.

A seguir, encontra-se a formulação matemática, adaptada de Jeronymo [Jeronymo, 2013] e Coelho e Mariani [Coelho e Mariani, 2006], para o PDEEE.

A Equação (1) representa a função objetivo do problema, que retorna um valor monetário do custo de produção por intervalo de tempo. A Equação (2) é a restrição de igualdade da potência produzida com a quantidade de energia demandada. A Equação (3) é uma restrição, que representa os limites de produção de cada UG_i .

Função Objetivo:

$$\text{minimizar } F(\vec{P}) = \sum_{i=1}^n a_i P_i^2 + b_i P_i + c_i + |e_i \sin(f_i(P_i^{\text{min}} - P_i))| \quad (1)$$

Sujeito a:

$$\sum_{i=1}^n P_i - P_D = 0 \quad (2)$$

$$P_i^{\text{min}} \leq P_i \leq P_i^{\text{max}} \quad (3)$$

Em que \vec{P} é o vetor das variáveis de decisão; P_i é a potência produzida pela UG_i (em MW); P_i^{min}

e P_i^{max} são os limites de potência mínimos e máximos de cada UG_i respectivamente (em MW); P_D é a potência demandada (em MW); a_i , b_i e c_i são constantes relacionadas às características de cada gerador i ; e_i e f_i são constantes relacionadas ao efeito de ponto de válvula; $i \in \mathbb{N}^*$; n é o número de unidades geradoras.

3. Conceitos de Incertezas

Considerar as incertezas é importante, pois a presença delas pode deteriorar soluções nominais [Ben-Tal et al., 2009]. De acordo com a comunidade científica, existem muitos tipos de incertezas. O problema é identificar e caracterizá-las/quantificá-las. [Beyer e Sendhoff, 2007] destacam 4 tipos de incertezas:

A – Mudanças do ambiente e das condições de operação, envolvem: temperatura de operação, pressão, umidade e alteração das propriedades do material;

B – Tolerâncias de produção e imprecisão do atuador: estão relacionadas com a precisão do produto a ser produzido. Uma perturbação das variáveis de decisão;

C – Saída do sistema: envolvem imprecisão no cálculo das saídas do sistema, seja por erros em medições ou aproximações para modelos originais;

D – Viabilidade: envolvem as restrições que as variáveis de projeto devem obedecer.

As incertezas paramétricas estão relacionadas com as variáveis de decisão do problema. Um exemplo, são as incertezas dos tipos A e B. As incertezas paramétricas estão no escopo deste trabalho, pois o PDEEE está sujeito a este tipo de incerteza.

Beyer e Sendhoff [Beyer e Sendhoff, 2007] definem 3 tipos de quantificação das incertezas: As do tipo determinístico, que são determinadas por um intervalo de variação; as do tipo probabilístico, que descrevem a probabilidade de certo evento ocorrer; e as do tipo possibilístico, em que são definidas medidas *fuzzy* que descrevem a possibilidade de certo evento ocorrer.

4. Conceitos de Robustez

A noção de robustez é um conceito usado para definir as características esperadas de uma solução robusta [Gupta e Rosenhead, 1968].

Existem 4 conceitos clássicos: solução, decisão, conclusão e método robusto [Vincke, 2003].

- A decisão robusta é aquela que mantém um número relevante de planos para o futuro;
- A solução robusta é boa em todas ou na maioria das versões, sendo que versão é um conjunto plausível de valores para as incertezas do modelo;
- A conclusão robusta é válida em todas ou na maioria das versões, sendo que versão é um conjunto aceitável para os parâmetros do modelo de decisão;
- O método robusto é o que retorna resultados válidos em todas ou na maioria das versões, em que uma versão é um conjunto dos valores possíveis para as incertezas do problema e para os parâmetros do método.

Uma solução, para ser considerada robusta, deve na presença das incertezas, pouco alterar-se, manter-se viável / factível e respeitar as restrições definidas para o problema [Mendes, 2013].

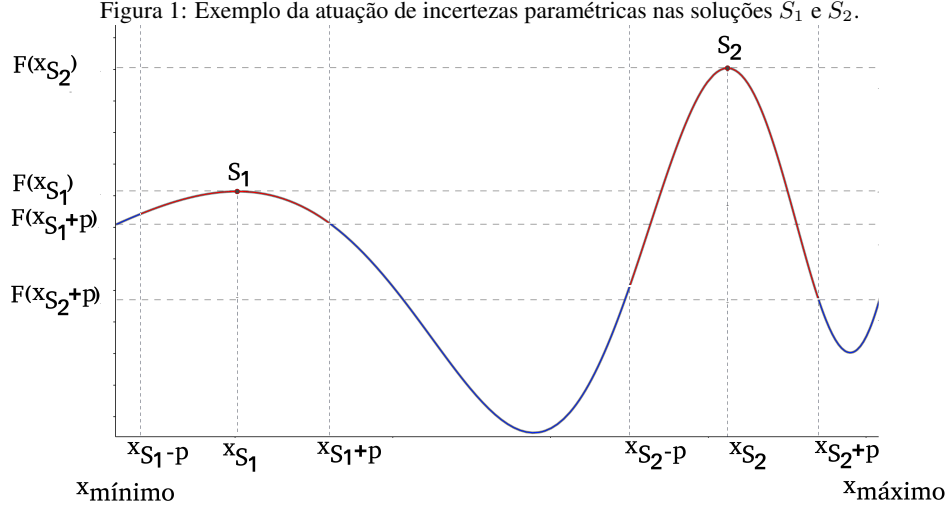
A forma de mensurar o desempenho das soluções quando sujeitas às incertezas é chamada de medida robusta. As medidas robustas mais comuns são as da função de *fitness*¹ esperada: média explícita; média implícita; ou cenário de pior caso. A última visa garantir que, mesmo na pior atuação das incertezas, serão produzidas soluções factíveis e com bom desempenho [Goh et al., 2007].

Para ilustrar a importância de se obter soluções robustas, na Figura (1) aborda-se um problema de maximização. A solução S_2 é o ótimo global e a solução S_1 é um ótimo local, ambas,

¹*fitness* é um valor numérico atribuído a uma solução afim de quantificá-la.

dentro do domínio $x_{\text{mínimo}}$ e $x_{\text{máximo}}$. Neste cenário, as soluções S_1 e S_2 estão sujeitas às incertezas na variável de decisão x , e podem variar no intervalo $[x_{S_1} - p, x_{S_1} + p]$ e $[x_{S_2} - p, x_{S_2} + p]$, respectivamente. Dessa forma, os valores de $F(x_{S_1})$ e $F(x_{S_2})$ estão suscetíveis às alterações.

Para o pior caso de atuação das incertezas, $F(x_{S_1})$ é melhor que $F(x_{S_2})$, pois $F(x_{S_1} + p)$ é maior que $F(x_{S_2} + p)$. A solução S_1 é dita mais robusta que a S_2 .



5. Versão Robusta do Problema do Despacho Econômico de Energia Elétrica (RPDEEE)

A versão robusta do PDEEE, proposta para este trabalho (RPDEEE), caracteriza-se pela inserção das incertezas paramétricas no processo de otimização. Adotou-se as incertezas do tipo A e B, definidas por Beyer e Sendhoff [Beyer e Sendhoff, 2007], e serão tratadas de forma determinística. Para otimização robusta foi adotado o método robusto, cujo objetivo é encontrar soluções que permanecem factíveis mesmo no pior caso de atuação das incertezas. A seguir, encontra-se a formulação matemática, que considera as incertezas paramétricas.

Função Objetivo:

$$\text{minimizar } F(\vec{P}_m) = \sum_{i=1}^n a_i P_{mi}^2 + b_i P_{mi} + c_i + |e_i \sin(f_i(P_i^{\text{min}} - P_{mi}))| \quad (4)$$

Sujeito a:

$$0 \leq \sum_{i=1}^n P_{mi} - P_D \leq T \quad (5)$$

$$P_i^{\text{min}} \leq P_{mi} \leq P_i^{\text{max}} \quad (6)$$

$$P_{mi} = P_i \pm P_{pi} \quad (7)$$

$$P_{pi} = r I_i \frac{(P_i^{\text{min}} + P_i^{\text{max}})}{2} \quad (8)$$

A Equação (4) representa a função objetivo a ser minimizada na presença de incertezas; A Equação (5) é um relaxamento da restrição da Equação (2); a Equação (6) determina os limites da produção de cada UG_i na presença de incertezas; e as Equações (7) e (8) estão relacionadas com as perturbações realizadas nas potências produzidas por cada UG_i .

r é um número pseudo aleatório entre 0 e 1; \vec{P}_m é o vetor das variáveis de decisão que consideram as perturbações; P_{mi} é a potência da UG_i considerando as incertezas paramétricas P_{pi} na produção da potência nominal P_i ; I_i é o percentual unitário de variação (incerteza) que a UG_i está sujeita, com $I_i \in \mathbb{R}^+$; T é uma tolerância ligada a um relaxamento da potência demandada (um percentual de P_D).

6. Algoritmos Genéticos

Algoritmos Genéticos (AGs) é uma meta-heurística dentro da área de computação evolucionária [Holland, 1975]. Baseia-se em uma metáfora do processo de seleção natural de Charles Darwin e recombinação gênica observados na natureza.

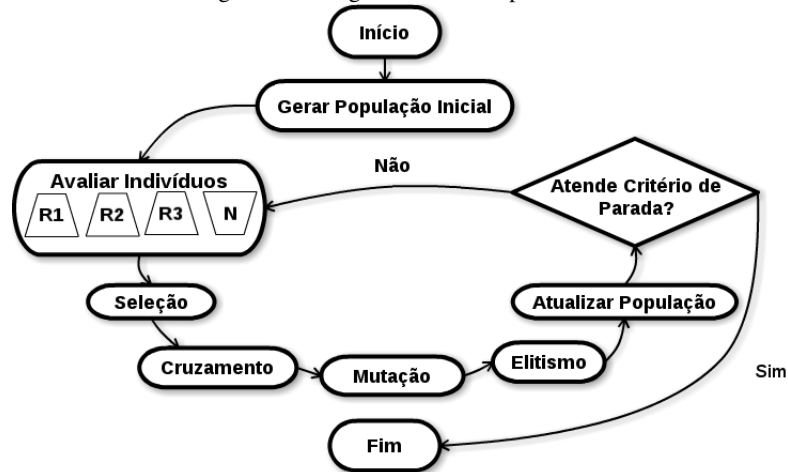
Inicialmente, cria-se uma população inicial de indivíduos, cada indivíduo representa uma solução viável para o problema. Essa população é alterada com as gerações do algoritmo, a partir da seleção dos indivíduos mais aptos e dos operadores genéticos: cruzamento e mutação. Esses operadores combinam soluções, afim de melhorá-las. Assim, com o passar das gerações, há uma tendência de convergência para soluções ótimas. No entanto, não há garantias de que o problema seja resolvido e nem que a melhor resposta seja obtida [Michalewicz, 2013; Linden, 2006].

As vantagens dos AGs são: aplicação em problemas com demasiado espaço de busca; facilidade de implementação; flexibilidade para tratamento de restrições e incertezas; adaptabilidade a diversos problemas; e velocidade de convergência [Michalewicz, 2013].

7. Algoritmo Genético implementado

O algoritmo genético (AG) implementado possui codificação real, por isso os indivíduos são representados como um vetor de n números reais. A etapa de avaliação dos indivíduos, como mostra o fluxograma da Figura (2), pode ser feita de 4 formas (e deve ser escolhida antes da sua execução): 1 forma nominal (N), em que as incertezas não são consideradas, assim os valores de I_i na Equação (8) são 0; e 3 formas robustas (R1, R2 ou R3) que consideram as incertezas dentro do processo de otimização. O critério de parada usado foi um limite de avaliações da função objetivo (Equação (4)).

Figura 2: Fluxograma do AG implementado.



7.1. Descrição das técnicas para tratamento das incertezas paramétricas

As técnicas R1, R2 e R3, adotam a medida robusta baseada no cenário de pior caso. A seguir, é descrito como cada técnica funciona:

- Na técnica R1, cada indivíduo J_i da população de filhos (λ) tem sua *fitness* determinada pela pior *fitness* de uma população (conjunto de amostras) de m indivíduos perturbados. A população de indivíduos perturbados têm os valores do seu vetor \vec{P}_m modificados de acordo com a Equação (7). Portanto, o pior caso de atuação das incertezas é obtido por meio do uso de um conjunto de amostras.

- Na técnica R2, cada indivíduo J_i da população de filhos (λ) é determinado por uma execução interna de outra instância de um AG (AG_j). Tal execução objetiva encontrar o pior caso de atuação das incertezas para o indivíduo J_i . O AG_j tem a população inicial derivada do indivíduo J_i com o uso da Equação.(7), a seleção é feita por torneio e baseia-se em escolher o pior indivíduo (pior valor de *fitness*). Ao fim do AG_j a *fitness* do seu pior indivíduo (isto é, aquele que representa o pior caso de atuação das incertezas) substitui o valor de *fitness* do indivíduo J_i .
- Na técnica R3 cada indivíduo J_i da população de filhos (λ) têm os elementos do seu vetor \vec{P}_m alterados. A alteração ocorre da seguinte forma: pega-se um elemento de \vec{P}_m e acrescenta-se uma perturbação P_{pi} ao respectivo elemento P_{mi} (com o uso da Equação (8)), até que seu valor de *fitness* atinja o maior valor possível dentro de um limite de análises (l_a). Esse procedimento é repetido pra todos os elementos de \vec{P}_m em J_i .

8. Experimento e Análises

Foram usados os seguintes parâmetros: População inicial heurística; seleção por *ranking*; cruzamento $blx-\alpha$; mutação múltipla não uniforme; tipo de população $\mu + \lambda$; elitismo; tamanho da população de pais $\mu = 16$; tamanho da população de filhos $\lambda = 32$; probabilidade de cruzamento $cx = 0,80$; probabilidade de mutação $mx = 0,05$ [Michalewicz, 2013; de Lacerda e de Carvalho, 1999];

$P_D = 1800$; $n = 13$; $m = 100$; $l_a = 100$ e $T = 0,01$; limite de avaliações da função objetivo $60000 * n$ [Cesaro et al., 2014]. Os demais parâmetros estão presentes na Tabela (1) tal como em [Jeronymo, 2013].

Tabela 1: Valores de: P_i^{min} , P_i^{max} , a_i , b_i , c_i , e_i , f_i e I_i .

i	P_i^{min}	P_i^{max}	a_i	b_i	c_i	e_i	f_i	I_i
1	0	680	0,00028	8,1	550	300	0,035	0,01
2	0	360	0,00056	8,1	309	200	0,042	0,01
3	0	360	0,00056	8,1	307	150	0,042	0,01
4	60	180	0,00324	7,74	240	150	0,063	0,01
5	60	180	0,00324	7,74	240	150	0,063	0,01
6	60	180	0,00324	7,74	240	150	0,063	0,01
7	60	180	0,00324	7,74	240	150	0,063	0,01
8	60	180	0,00324	7,74	240	150	0,063	0,01
9	60	180	0,00324	7,74	240	150	0,063	0,01
10	40	120	0,00284	8,6	126	100	0,084	0,01
11	40	120	0,00284	8,6	126	100	0,084	0,01
12	55	120	0,00284	8,6	126	100	0,084	0,01
13	55	120	0,00284	8,6	126	100	0,084	0,01

Fonte: Adaptado de Jeronymo, (2013, p. 69).


O experimento realizado constitui-se de 4 instâncias, cada instância é formada por 100 amostras. As amostras N , $R1$, $R2$ e $R3$ foram obtidas por execuções do AG implementado, com a respectiva técnica de avaliação dos indivíduos.

Para simular o pior cenário de ocorrência das incertezas sobre as soluções nominais (N), foi criada outra instância (N_P). Cada amostra i em N_P é determinada pela pior de 100 perturbações em cada amostra i de N .

A Figura (3) mostra um comparativo entre as soluções nominais, nominais perturbadas e robustas. As soluções nominais, representadas por (\square), são as que apresentam os melhores custos.

As soluções nominais perturbadas, representadas por (Δ) são as piores, e evidenciam a sensibilidade das soluções nominais às incertezas paramétricas.

Figura 3: Instâncias: N , $R1$, $R2$, $R3$ e N_P .



Os valores de *fitness* das soluções nominais encontradas neste trabalho, aproximam-se dos melhores resultados disponíveis na literatura. A melhor solução encontrada, na literatura, tem custo 17960,36 MW/h [Cesaro et al., 2014], a deste trabalho é 17960,50 MW/h o que mostra a eficiência do AG implementado.

Na Figura (3), todas as soluções robustas estão acima das nominais e abaixo das nominais perturbadas. Este resultado é esperado, pois as soluções robustas tendem a ser piores que as soluções nominais. Como as soluções robustas estão baseadas no cenário de pior caso, há uma tendência delas se aproximarem das nominais perturbadas.

Tabela 2: Estatísticas descritivas das instâncias: N , $R1$, $R2$, $R3$ e N_P .

Instância	Valor da função <i>fitness</i>			Desvio padrão
	Mínima	Média	Máxima	
N	17960,50	18014,57	18084,10	27,18
$R1$	17980,30	18099,61	18218,80	47,93
$R2$	17991,80	18089,85	18176,50	37,78
$R3$	18001,20	18105,18	18207,10	42,21
N_P	18078,60	18160,93	18259,20	34,07

A Tabela (2) contém as estatísticas descritivas das instâncias N , $R1$, $R2$, $R3$ e N_P . As 5 instâncias apresentam desvio padrão pequeno, isso indica que o algoritmo encontra resultados relativamente próximos da média. Também estão destacados em negrito os seus piores valores, e é possível notar que as soluções da instância N_P apresentam os piores resultados. Dentre as soluções robustas, $R2$ é a de melhor, pois apresenta menor média e menor desvio.

Como visto no exemplo da Figura (1), uma solução robusta tende a deteriorar-se menos

na presença de incertezas. Este é o caso das soluções robustas obtidas neste trabalho, pois quando submetidas às incertezas, as soluções $R1$, $R2$ e $R3$ mantêm-se melhores que as soluções nominais perturbadas.

9. Conclusão

As soluções nominais tem um aumento considerável de custo. As soluções robustas obtidas com o uso das técnicas $R1$, $R2$ e $R3$ mostram-se melhores que as soluções nominais para o RPDEEE, devido à considerável piora nos valores de *fitness* das soluções nominais quando submetidas ao pior caso de atuação das incertezas paramétricas. Todas as soluções robustas encontradas, mesmo no pior cenário de atuação das incertezas, apresentam custos menores que os das soluções nominais perturbadas.

10. Agradecimentos

Os autores agradecem o apoio financeiro parcial fornecido pela FAPEMIG por meio do programa institucional de bolsas de iniciação científica e tecnológica.

Referências

- Ben-Tal, A., El Ghaoui, L., e Nemirovski, A. (2009). *Robust optimization*. Princeton University Press.
- Beyer, H.-G. e Sendhoff, B. (2007). Robust optimization—a comprehensive survey. *Computer methods in applied mechanics and engineering*, 196(33):3190–3218.
- Cesaro, E., Czaikoski, G. H., Gonçalves, R. A., Almeida, C., e Venske, J., S. ; Kuk (2014). Evolução diferencial com múltiplos vetores experimentais aplicada ao problema do despacho econômico de energia elétrica. *Encontro Nacional de Inteligência Artificial e Computacional*.
- Coelho, L. d. S. e Mariani, V. C. (2006). Otimização de despacho econômico com ponto de válvula usando estratégia evolutiva e método quase-newton. *Learning and Non linear Models-Revista da Sociedade Brasileira de Redes Neurais (SBRN)*, 4(1).
- de Lacerda, E. G. e de Carvalho, A. (1999). Introdução aos algoritmos genéticos. *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*, 1:99–148.
- Goh, C. K., Tan, K. C., Cheong, C. Y., e Ong, Y.-S. (2007). Noise-induced features in robust multi-objective optimization problems. In *Evolutionary Computation, 2007. CEC 2007. IEEE Congress on*, f. 568–575. IEEE.
- Gupta, S. K. e Rosenhead, J. (1968). Robustness in sequential investment decisions. *Management science*, 15(2):B–18.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. U Michigan Press.
- Jeronymo, D. C. (2013). Metaheurísticas aplicadas ao problema de despacho econômico de energia elétrica. f. 141. Mestrado em engenharia elétrica, Programa de Pós-Graduação em Engenharia elétrica, Universidade Federal do Paraná, Curitiba, 2013.
- Linden, R. (2006). *Algoritmos genéticos: uma importante ferramenta da inteligência computacional*. Brasport, 2^a edition.
- Mendes, M. H. S. (2013). *Algoritmos evolucionários intervalares para otimização robusta multi-objetivo*. f. 119. Doutorado em engenharia elétrica, Programa de Pós-Graduação em Engenharia elétrica, Universidade Federal de Minas Gerais, Minas Gerais, 2013.
- Michalewicz, Z. (2013). *Genetic Algorithms + Data Structures = Evolution Programs*. Springer Science & Business Media.
- Vincke, P. (2003). About robustness analysis. *EWG-MCDA Newslett*, 3(8):7–9.