



**UNIVERSIDADE FEDERAL DO OESTE DO PARÁ – UFOPA
INSTITUTO DE ENGENHARIA E GEOCIÊNCIAS – IEG
BACHARELADO INTERDISCIPLINAR EM CIÊNCIA E TECNOLOGIA**

PATRICK VASCONCELOS DA SILVA

**COLONIA DE ABELHAS ARTIFICIAIS APLICADA AO PROBLEMA DO
CAIXEIRO VIAJANTE COM VISTAS A RECARGA DE COMBUSTÍVEIS EM
REATORES NUCLEARES**

SANTARÉM

2016

PATRICK VASCONCELOS DA SILVA

**COLONIA DE ABELHAS ARTIFICIAIS APLICADA AO PROBLEMA DO
CAIXEIRO VIAJANTE COM VISTAS A RECARGA DE COMBUSTÍVEIS EM
REATORES NUCLEARES**

Trabalho de Conclusão de Curso apresentado ao
Bacharelado Interdisciplinar em Ciência e Tecnologia
para obtenção do grau de Bacharel em Ciência e
Tecnologia na Universidade Federal do Oeste do Pará,
Instituto de Engenharia e Geociências.

Orientador: Anderson Alvarenga de Moura Meneses

SANTARÉM

2016

COLÔNIA DE ABELHAS ARTIFICIAIS APLICADA AO PROBLEMA DO CAIXEIRO VIAJANTE COM VISTAS À RECARGA DE COMBUSTÍVEIS EM REATORES NUCLEARES

Patrick V. da Silva¹, Fernando N. Nast², Marcel. A. A. Romano³ e Anderson A. M. Meneses⁴

¹ Laboratório de Inteligência Computacional - Instituto de Engenharia e Geociências
Universidade Federal do Oeste do Pará
Santarém, PA
patrickvs@hotmail.com

² Laboratório de Inteligência Computacional - Instituto de Engenharia e Geociências
Universidade Federal do Oeste do Pará
Santarém, PA
fnnast@hotmail.com

³ Laboratório de Inteligência Computacional - Instituto de Engenharia e Geociências
Universidade Federal do Oeste do Pará
Santarém, PA
antonionni@gmail.com

⁴ Laboratório de Inteligência Computacional - Instituto de Engenharia e Geociências
Universidade Federal do Oeste do Pará
Santarém, PA
anderson.meneses@pq.cnpq.br

RESUMO

O problema de Otimização do Gerenciamento de Combustível Intra-Núcleo (*In-Core Fuel Management Optimization*; OGCIN) é um problema associado à operação de recarga de combustível em um reator nuclear, que consistem em determinar a combinação de Elementos Combustíveis (EC) de forma que o desempenho do reator nuclear seja melhorado. Este é um problema clássico e uma questão de grande interesse econômico de extrema relevância para a Engenharia Nuclear, que vem sendo estudado a mais de quarenta anos. Problemas de análise combinatória são problemas de difícil solução, pois o número de possíveis soluções do problema cresce de forma exponencial de acordo com a quantidade de elementos. Além desse fato, a OGCIN se torna ainda mais difícil, pois cada solução encontrada deve ser testada por complexos cálculos de Física de Reatores. Uma abordagem que vem sendo bem-sucedida é a aplicação de Metaheurísticas de otimização. A validação de algoritmos aplicados à OGCIN é feita utilizando problemas *benchmark*, tais como o Problema do Caixeiro Viajante (PCV). No presente trabalho, com o intuito de fazer uma iniciação às técnicas de Inteligência Artificial que podem ser aplicadas na Engenharia Nuclear, implementamos o algoritmo Artificial Bee Colony (ABC) e o aplicamos à solução do PCV *Oliver30*, analisando os resultados com vistas à sua aplicação à OGCIN. O ABC foi apresentado inicialmente por Karaboga (2005) e aplicado ao OGCIN por Oliveira e Schirru (2011). O ABC baseia-se na inteligência coletiva de um enxame de abelhas melíferas reais na busca por alimento. Apresentamos os resultados preliminares do algoritmo ABC na resolução do PCV *Oliver30*, para posterior aplicação a outros PCVs e em seguida ao OGCIN.

1. INTRODUÇÃO

O problema de Otimização do Gerenciamento de Combustível Intra-Núcleo (*In-Core Fuel Management Optimization*; OGCIN), ou otimização do projeto de Padrões de Carregamento (PCs) são denominações para o problema de otimização associado à operação de recarga de

combustível em um reator nuclear, que é um problema clássico e uma questão de grande interesse econômico de extrema relevância para a Engenharia Nuclear, que vem sendo estudado a mais de quarenta anos. O OGCIN é considerado um problema de difícil resolução tanto por ser classificado como NP-difícil levando em conta aspectos da otimização combinatória, quanto pela própria complexidade dos cálculos de análise e física de reatores. Partindo desse preceito, a aplicação de métodos de inteligência computacional e metaheurísticas de otimização tem se mostrado promissoras na solução de problemas de análise combinatória. Diversas Metaheurísticas foram bem-sucedidas quando aplicadas à OGCIN, tais como Simulated Annealing (SA) (Parks, 1990; Stevens et. al., 1995), Genetic Algorithm (GA) (Poon e Parks, 1992; Parks, 1996; DeChaine e Feltus, 1996; Chapot et. al. 1999), Tabu Search (TS) (Lin et. al., 1998), Population-Based Incremental Learning (PBIL) (Machado, 1999, 2005; Schirru et. al., 2006; Caldas e Schirru, 2008), Ant Colony Optimization (ACO) (Machado e Schirru, 2002; De Lima, 2005; Schirru et. al., 2006; De Lima et. al., 2007, 2008), Particle Swarm Optimization (PSO) (Meneses et. al., 2009), Artificial Bee Colony (ABC) (Oliveira e Schirru, 2011) e Cross-Entropy (Meneses e Schirru, 2015).

Tais algoritmos fazem parte do paradigma de Inteligência de Enxame. Este paradigma tem como foco grupo de agentes com inteligência limitada, onde as interações entre esses agentes contribuem para inteligência coletiva. As heurísticas de inteligência de enxame têm sido adaptadas de forma bem-sucedida à problemas de otimização. Ant Colony Optimization (ACO) (Dorigo e Gambardella, 1997) e Particle Swarm Optimization (PSO) (Kennedy e Eberhart, 1995) são alguns dos algoritmos bem conhecidos que simulam o comportamento de insetos em modelagem de problemas e solução (Baykasoglu et al., 2007).

O algoritmo de Colônia de Abelhas Artificiais (Artificial Bee Colony; ABC) (Karaboga, 2005; Karaboga and Basturk, 2007, 2008) é um dos membros da família de algoritmos de inteligência de enxame, que busca simular o comportamento de abelhas em busca de alimento. O ABC foi aplicado à OGCIN por Oliveira e Schirru (2011), e mostrou resultados promissores.

O presente trabalho visa a validação do ABC, utilizando problemas *benchmark*, para posterior aplicação à OGCIN, apresentando resultados preliminares da aplicação do ABC ao PCV *oliver30*.

No restante do trabalho foi organizado da seguinte forma: Na seção 2 apresentamos os aspectos básicos da OGCIN e as particularidades do problema do padrão de carregamento na Usina Nuclear de Angra 1, na seção 3 a descrição dos principais passos do Algoritmo ABC, os resultados do ABC aplicado ao problema *benchmark* PCV *oliver30* foram descritos na seção 4 e as conclusões e futuros passos da pesquisa estão na seção 5.

2. O PROBLEMA DE OTIMIZAÇÃO DE COMBUSTÍVEL INTRA-NÚCLEO

A recarga de um reator nuclear faz-se necessária quando a queima de Elementos Combustíveis (EC) no núcleo do reator não é suficiente para manter o Reator funcionando a potência nominal ou após um período de operação chamado de ciclo.

Devido ao fato de a queima do EC depender de sua posição no núcleo do reator, é comum que após cada ciclo os ECs apresentem características neutrônicas diferentes, ou seja, os ECs são queimados de formas distintas, conseqüentemente, os ECs que não são queimados por completo são reutilizados no ciclo seguinte, logo, no processo de recarga apenas uma fração

dos ECs é substituída por novos. Sendo assim, o núcleo do próximo ciclo é formado por novos ECs e por ECs reutilizados, a combinação formada por esses ECs no núcleo do reator são o chamado padrão de carregamento (PC).

O problema de Otimização do Gerenciamento de Combustível Intra-Núcleo (OGCIN) consiste em determinar o PC de forma que satisfaça as regras de simetria do núcleo do reator e prolongue a duração do ciclo de recarga ou minimize o fator de pico de potência radial do núcleo (F_{xy}), atendendo a restrições de segurança (Machado, 2005).

Por exemplo, se o objetivo for prolongar a duração do ciclo de recarga, é indicado o posicionamento dos novos ECs nas posições mais internas do núcleo e consequentemente posicionando os ECs reutilizados nas periferias, essa configuração recebe o nome de baixa-fuga, pois nela a fuga de nêutrons do núcleo para o vaso do reator é reduzida, o contra desse PC é que o aparecimento de picos de potência do núcleo é reduzido.

No entanto, se o objetivo for minimizar o fator de pico de potência radial (F_{xy}) o PC é a out-in, onde os ECs são posicionados nas regiões de periferia do núcleo. O contra desse PC é que ocorre uma alta fuga de nêutrons do núcleo para o vaso do reator, o que pode danificar a estrutura e comprometer a vida útil da usina nuclear.

Isso torna a OGCIN um problema complexo, por se tratar de um problema de otimização multi-objetivo (em que geralmente estes problemas são conflitantes) em aspectos econômicos, operacionais e de segurança. Além disso, o reator possui características altamente não-lineares, tratando-se de um problema combinatório com inúmeros mínimos locais.

Além disso, a OGCIN é classificada como problema de NP-difícil, o que significa que sua dificuldade cresce com o número de EC de forma exponencial. Por exemplo, o núcleo reator de angra 1 é constituído de 121 ECs, o que gera cerca de $8,09 \times 10^{200}$ soluções possíveis. Contudo, no núcleo existem eixo de simetria que reduzem a complexidade para $2,43 \times 10^{18}$ combinações possíveis, que ainda é extremamente alto para resolver por enumeração.

Todas essas características associadas tornam a OGCIN um problema de otimização excepcional, desafiando os métodos de otimização tradicionais e fomentando o desenvolvimento de novos métodos inteligentes.

A aplicação de novas metodologias à OGCIN tem obtido resultados considerados bem-sucedidos (Parks, 1990; Poon e Parks, 1992; Stevens et al., 1995; DeChaine e Feltus, 1996; Chapot et al., 1999; Chapot, 2000; Machado e Schirru, 2002; Schirru et al., 2006; Caldas e Schirru, 2008; De Lima et al., 2008; Meneses et al., 2009; Oliveira e Schirru, 2011; Meneses e Schirru, 2015).

3. ALGORITMO DE COLÔNIA DE ABELHAS ARTIFICIAIS (ABC)

O Algoritmo ABC foi inicialmente proposto por Dervis Karaboga (KARABOGA, 2005) como metaheurística de inteligência de enxame aplicada a otimização de funções multimodais e de múltiplas variáveis em espaços de busca contínuos. A primeira aplicação do ABC à OGCIN foi feita por Oliveira e Schirru (2011).

O ABC tenta simular o comportamento de abelhas melíferas em busca de fontes alimento. No algoritmo, as fontes de alimento são as soluções, onde cada fonte tem um néctar associado e a quantidade de néctar define a aptidão da fonte de alimento. A colônia de abelhas é subdividida em três grupos: Abelhas Operárias, Abelhas Observadoras e Abelhas Exploradoras.

Metade da colônia é formada por abelhas operárias e a outra metade é formada por abelhas observadoras. As abelhas operárias são abelhas que já exploram determinada fonte de alimento e compartilham informações sobre a fonte com as abelhas observadoras. Com base nas informações compartilhadas as abelhas observadoras decidem qual a melhor fonte a ser explorada, e passam a ser operárias dessa fonte. Já as abelhas exploradoras são abelhas operárias que estão posicionadas em fontes estagnadas, e são reenviadas em buscas de novas fonte de alimento de forma aleatória. A seguir temos os principais passos do algoritmo:

- (i) Inicialização da população de fontes de alimento;
- (ii) Cada abelha operária explora uma nova fonte na vizinhança da sua fonte inicial e passa a explorar a melhor fonte entre elas;
- (iii) Com base na quantidade de néctar as abelhas observadoras são posicionadas nas fontes existentes, em seguida exploram uma nova fonte na vizinhança da sua posição atual e passam a explorar a melhor fonte entre elas;
- (iv) É testado o critério de decisão para determinar se a abelha operária passará a ser exploradora, se sim a abelha exploradora é enviada em busca de novas fontes de alimento;
- (v) A melhor fonte é memorizada;
- (vi) Os passos (ii - v) são repetidos até que os critérios de parada sejam alcançados.

No primeiro passo posicionamos cada abelha operária em uma fonte de alimento utilizando a equação 1:

$$x_{ij} = x_j^{\min} + (x_j^{\max} - x_j^{\min}) * rand \quad (1)$$

Onde temos $i = 1, \dots, SN$, $j = 1, \dots, D$, onde D é a dimensão do problema e $rand$ é um número aleatório no intervalo $[0,1]$. No segundo passo é executada busca local, onde cada abelha operária explora uma fonte na vizinhança (v_{ij}) utilizando a equação 2:

$$v_{ij} = x_{ij} + \varphi_{ij}(x_{ij} - x_{kj}) \quad (2)$$

Onde φ_{ij} é um número aleatório no intervalo $[-1,1]$, $k = 1, \dots, SN$ sendo que $k \neq i$. Após a produção da nova fonte \vec{v}_i , ela é comparada com \vec{x}_i e a abelha operária passa a explorar a melhor entre elas. No terceiro passo é utilizado o compartilhamento de informação, onde são selecionadas fontes \vec{x}_i com base na probabilidade da equação 3, e é criada uma cópia com as melhores fontes. A partir dessas melhores fontes são produzidas fontes na vizinhança \vec{v}_i , que

formarão as fontes das abelhas observadoras. Estas fontes são comparadas com \vec{x}_i , e as abelhas operárias passam a explorar a melhor solução entre elas.

$$p_i = \frac{fit_i}{\sum_{j=1}^{SN} fit_j} \quad (3)$$

Onde fit_i é a fitness da fonte i .

No quarto passo o critério de parada é testado. Se a fonte \vec{x}_i não melhorar após um *limite* (4) predefinido de ciclos ela é abandonada e a abelha operária dessa fonte se torna uma exploradora e é enviada à procura de uma nova fonte utilizando a equação 1, onde em relacionamos aspectos de busca global.

O ABC apresenta, além dos parâmetros comuns com tamanho do enxame e número de iterações, apenas um parâmetro de controle, o limite, que é sugerido pela literatura como o produto entre o número de fontes e a dimensão do problema:

$$limite = SN * D \quad (4)$$

A codificação dos resultados obtidos é feito utilizando a metodologia Random Keys. O modelo Random Keys foi proposto por Bean (1994) e consiste em codificar vetores de possíveis soluções, em que cada elemento do vetor assume um valor real entre 0 e 1. Em outras palavras, ele codifica e decodifica uma solução de números reais, e elas são a chave para ordenar outros números a fim de formar uma possível solução para o problema de otimização.

O funcionamento da Random Keys está exemplificado na Fig. 1, onde chave ($s_i = \{0,35; 0,61; 0,11; 0,86; 0,47\}$) é gerada de forma aleatória, e temos associada a cada posição um número inteiro (1; 2; 3; 4; 5), quando esta solução é decodificada obtemos como solução associada (3; 1; 5; 2; 4), pois a chave é ordenada de forma crescente, ordenando também os números inteiros associados a ela.




Figura 1: exemplificação da Random Keys: (a) chave produzida aleatoriamente, (b) vetor associado a chave e (c) possível solução codificada a partir de (a).

Adaptação feita para o ABC é que cada fonte de alimento obtida a partir do código é utilizada como chave para a produção de possíveis soluções, que são avaliadas usando a função objetivo do problema em questão.

4. O ABC APLICADO AO PROBLEMA DO CAIXEIRO VIAJANTE

O Problema do Caixeiro Viajante (PCV) é um problema de análise combinatória classificado como NP-difícil cuja soluções viáveis são conjuntos discretos, correspondendo a permutações da sequência de cidades a serem visitadas (Lawler et al., 1985; Papadimitriou e Steiglitz, 1982). O PCV consiste em determinar o trajeto de menor distância, visitando cada cidade uma vez e retornando para a cidade inicial. Apesar da simples formulação, o PCV é um problema de difícil solução, e é referência em otimização combinatória.

Existem dois principais tipos de PCV: os simétricos e os assimétricos. O PCV simétrico é aquele onde dadas duas cidades i e j diferentes, a distância d_{ij} para ir de uma a outra é igual ao caminho inverso, isto é, $d_{ij} = d_{ji} \forall i, j = 1, \dots, n$. Consequentemente, o PCV simétrico tem $[(n - 1)!]/2$ soluções possíveis, já o PCV no assimétrico $d_{ij} \neq d_{ji} \forall i \neq j$ e possui $(n - 1)!$ Soluções possíveis. O PCV é formulado Papadimitriou e Steiglitz, (1982) como problema de minimização.

4.1. Resultados da Aplicação do ABC ao *Benchmark Oliver30*

A fim de validar o código para o PCV *Oliver30* (Dorigo e Gambardella, 1997) (Meneses et. Al., 2009), que é um problema simétrico em que a menor distância conhecida é de 423,74. Foram executados dez testes independentes para cada um dos dois tamanhos de enxame diferentes, 100 e 200 abelhas, testando as variações de limite entre 1000 e $2 \cdot SN \cdot D$, vale ressaltar que a quantidade de fontes de alimento (SN) é corresponde à metade do tamanho do enxame. O número máximo de iterações do algoritmo foi definido em 20.000 (O total de avaliações por iteração é correspondente ao número de abelhas do enxame mais o número de avaliações das abelhas exploradoras).

Os melhores resultados estão na Tabela 1(100 abelhas) e na Tabela 2 (200 abelhas), onde os mínimos estão destacados em negrito.

Tabela 1: Algoritmo ABC Aplicado ao *Oliver30* com um Enxame de 100 Abelhas

Limite	3.000		1.500		1.000	
Teste	Iteração	Fitness	Iteração	Fitness	Iteração	Fitness
#1	5077	423,74	5339	423,74	4467	423,74
#2	9183	424,69	9183	423,74	7291	424,69
#3	11870	425,27	7194	430,81	13453	471,58
#4	8197	423,74	4092	423,74	3784	423,74
#5	16328	423,74	10291	423,74	7219	434,41
#6	13285	423,74	7100	423,74	17859	471,97
#7	5956	424,69	7740	424,69	10114	428,50
#8	15893	423,74	11506	424,69	4978	423,95
#9	7939	423,74	9696	423,74	5562	423,74
#10	6937	424,69	8336	424,69	5883	424,69
Média	-	424,18	-	424,73	-	435,10
Desvio Padrão	-	0,59	-	2,18	-	19,61

Tabela 2: Algoritmo ABC Aplicado ao *Oliver30* com um enxame de 200 Abelhas

Limite	6.000		3.000		1.500		1.000	
Teste	Iteração	Fitness	Iteração	Fitness	Iteração	Fitness	Iteração	Fitness
#1	13098	423,74	7505	423,74	9547	423,74	8508	423,74
#2	14939	424,69	10779	424,69	6793	424,69	5796	431,97
#3	15770	424,69	8189	430,82	18744	442,98	15857	442,98
#4	18208	423,74	8784	423,74	8340	425,99	6174	429,42
#5	14120	423,95	10836	424,69	5443	424,69	5864	424,69
#6	14889	423,74	11622	445,89	17737	438,38	6043	436,14
#7	8280	423,74	18266	424,69	8484	424,69	9750	424,69
#8	11603	423,74	10577	423,74	11389	424,12	6216	423,74
#9	7515	423,74	10546	423,74	6805	423,74	5604	423,95
#10	10604	423,74	9209	424,69	8192	423,74	5969	432,07
Média	-	423,95	-	427,04	-	427,68	-	429,34
Desvio Padrão	-	0,40	-	6,96	-	6,97	-	6,51

Os resultados obtidos são promissores, a partir deles podemos notar que o algoritmo demonstrou certa eficácia em encontrar a menor distância a ser percorrida, 423,74. Percebemos também um padrão de comportamento do algoritmo, que de acordo com os valores de média e desvio padrão, que tem sua precisão elevada de acordo com o aumento do limite. Apesar do número elevado de avaliações o algoritmo apresentou uma ótima convergência para o mínimo global do problema.

Ressaltando que o ABC apresenta um número reduzido de parâmetros, o que pode ser considerado uma vantagem, pois o ajuste de parâmetros do Algoritmo pode ser feito de maneira simples.

5. CONCLUSÃO

Neste trabalho apresentamos a aplicação do ABC à problema ao *benchmark* PCV *oliver30*, para futura aplicação à OGCIN. São apresentados os principais aspectos do algoritmo e os resultados de testes. Considerando que o enxame inicial não possui conhecimento prévio do problema e considerando que o Algoritmo proposto utiliza poucos parâmetros de controle, quando comparados a outros algoritmos, como o GA e o ACO, o ABC demonstrou desempenho considerável.

O próximo passo da pesquisa é a aplicação do ABC a outros *benchmarks* PCV, e futuramente a aplicação à OGCIN.

AGRADECIMENTOS

A.A.M.M. agradece o apoio financeiro do CNPq (Projeto no. 472912/2013-5). P.V.S. agradece o apoio da UFOPA e da FAPESPA. F.N.N. agradece o apoio da UFOPA.

REFERÊNCIAS

1. Baykasoglu, A., Ozbakir, L., Tapkan, P., “Artificial Bee Colony algorithm and its application to generalized assignment problem”. *Chan, F.T.S., Tiware, M.K. (Eds.), Swarm Intelligence: Focus on Ant and Particle Swarm Optimization. Itech Education and Publishing*, Vienna, Austria, 2007, pp. 113–114.
2. Bean, J.C., “Genetic algorithms and random keys for sequencing and Optimization”. *ORSA Journal of Computing*, 1994, 6 (2).
3. Caldas, G.H.F., Schirru, R., “Parameterless evolutionary algorithm applied to the nuclear reload problem”. *Annals of Nuclear Energy* 2008, 35, 583–590.
4. Chapot, J.L.C., Da Silva, F.C., Schirru, R., “A new approach to the use of genetic algorithms to solve the pressurized water reactor’s fuel management optimization problem”. *Annals of Nuclear Energy* 1999, 26, 641–655
5. Dechaine, M.D., Feltus, M.A., “Fuel management optimization using genetic algorithms and expert knowledge”, *Nuclear Science and Engineering*, 1996, 124, 178-187
- 6.
7. De Lima, A.M.M., “Recarga de Reatores Nucleares Utilizando Redes Conectivas de Colônias Artificias”, *D. Sc. thesis*, 2005, COPPE/UFRJ, Brazil.
8. De Lima, A.M.M., Machado, M.D., Medeiros, J.A.C.C., Schirru, R., “Study of heuristics in ant system for nuclear reload optimization. In: Proceedings of the International Nuclear Atlantic Conference”, 2007, INAC, Brazil.
9. De Lima, A.M.M., Schirru, R., Da Silva, F.C., Medeiros, J.A.C.C., “A nuclear reactor core fuel reload optimization using ant colony connective networks”. *Annals of Nuclear Energy*, 2008, 35, 1606–1612.
10. Dorigo, M., Gambardella, L.M., “Ant colony system: a cooperative learning approach to the traveling salesman problem”. *IEEE Transactions on Evolutionary Computation*, 1997, 1 (1), 53–66.
11. Karaboga, D., “An Idea Based on Honey Bee Swarm for Numerical Optimization”. *Technical Report – TR 06*, October 2005. Erciyes University, Engineering Faculty, Computer Engineering Department, Kayseri/Turkiye.
12. Karaboga, D., Basturk, B., “A powerful and efficient algorithm for numerical function optimization: Artificial Bee Colony (ABC) algorithm”. *Journal of Global Optimization*, 2007, 39 (3), 459–471.
13. Karaboga, D., Basturk, B., “On the performance of Artificial Bee Colony (ABC) Algorithm”. *Applied Soft Computing*, 2008, 8, 687–697.
14. Kennedy, J., Eberhart, R.C., “A new optimizer using particles swarm theory”. *Proceedings of Sixth International Symposium on Micro Machine and Human Science*, Nagoya, Japan. *IEEE Service Center*, Piscataway, 1995, NJ, pp. 39–43.
15. Lawler, E.L., Lenstra, J.K., Kan, A.H.G.R., Shmoys, D.B., “The Traveling Salesman Problem: a guided tour of combinatorial optimization”, 4a. ed. John Wiley & Sons, Wiltshire, 1985, Great-Britain.
16. Lin, C., Yang, J.-I., Lin, K.-J., Wang, Z.-D., “Pressurized water reactor loading pattern design using the simple tabu search”. *Nuclear Science and Engineering*, 1998, 129, 61–71.
17. Machado, M.D., “Algoritmo Evolucionário PBIL Multi-Objetivo Aplicado ao Problema da Recarga de Reatores Nucleares”, *D.Sc. thesis*, 2005, COPPE/UFRJ, Brazil.
18. Machado, M.D., “Um Novo Algoritmo Evolucionário com Aprendizagem LVQ para Otimização de Problemas Combinatórios como a Recarga de Reatores Nucleares”, *M. Sc. dissertation*, 1999, COPPE/UFRJ, Brazil.

19. Machado, L., Schirru, R., “The ant-Q algorithm applied to the nuclear reload problem”. *Annals of Nuclear Energy*, 2002, 29, 1455–1470.
20. Meneses, A.A.M., Machado, M.D., Schirru, R., “Particle swarm optimization applied to the nuclear reload problem of a pressurized water reactor” *Progress in Nuclear Energy*, 2009, 51, 319–326.
21. Meneses, A.A.M., Schirru, R., “A cross-entropy method applied to the In-core fuel management optimization of a Pressurized Water Reactor”, *Progress in Nuclear Energy*, 2015, 83, 326-335.
22. Oliveira, I.M.S., Schirru, R., “Swarm intelligence of artificial bees applied to In-Core Fuel Management Optimization” *Annals of Nuclear Energy*, 2011, 38, 1039–1045.
23. Oliveira, I.M.S., “Inteligência de Enxames Aplicada ao Problema de Otimização de Recarga de Reatores Nucleares a Água Pressurizada”, *D. Sc. thesis*, 2013, COPPE/UFRJ, Brazil.
24. Papadimitriou, C.H., Steiglitz, K., “Combinatorial Optimization”. Prentice-Hall, Inc, 1982, New Jersey.
25. Parks, G. T., “An intelligent stochastic optimization routine for nuclear fuel cycle design”, *Nuclear Technology*, 1990, 233-246.
26. Parks, G. T., “Multi-objective pressurized water reactor reload core design by non-dominated genetic algorithm search”, *Nuclear Science and Engineering*, 1996, 124, 178-187.
27. Poon, P.W., Parks, G.T., “Optimizing PWR reload core designs. Parallel Problem Solving from Nature II”, 373-382.
28. Schirru, R., De Lima, A.M.M., Machado, M.D., “Parallel evolutionary methods applied to a PWR core reload pattern optimization. In: Proceedings of the Seventh International Conference on Applied Artificial Intelligence”, 2006, FLINS, Italy.
29. Stevens, J.G., Smith, K.S., Rempe, K.R., “Optimization of pressurized water reactor shuffling by simulated annealing with heuristics”, *Nuclear Science and Engineering*, 1995, 121, 67-88.