

# Otimização de Grades de Bragg em Fibra Usando Processamento Paralelo e Algoritmo Genético

Marco José de Sousa, Lamartine Villar de Souza, Claudomiro Sales Junior, João Cláudio Chamma, Carlos Renato L. Francês e João Crisóstomo Weyl A. Costa, membro IEEE

**Resumo**— Neste trabalho são apresentados dois projetos de grades de Bragg em fibra usando processamento paralelo e algoritmo genético. Os resultados obtidos mostram a robustez dessa técnica quando aplicadas a espaços de pesquisa complexos. Além disso, mostra-se que uso do processamento paralelo permite um aumento do desempenho do algoritmo genético.

**Palavras chave**— Algoritmo Genético, Dispositivos Ópticos, Grades de Bragg em Fibra, Processamento Paralelo e MPI.

**Abstract**— In this work presented two projects of grating of Bragg in fiber using parallel processing and genetic algorithm. The obtained results show the robustness of that technique when applied to spaces of research complex. Besides, it is shown that use of the parallel processing allows an increase of the acting of the genetic algorithm.

**Index Terms**— Genetic Algorithm, Optical Devices, FBG, Message Passing Interface.

## I. INTRODUÇÃO

Existem muitas aplicações de otimização ou síntese de dispositivos que poderiam ser resolvidas com o auxílio de um algoritmo genético (GA). Uma dessas aplicações pode ser a otimização de grades de Bragg em fibra. De fato há vários motivos para a utilização de um GA ao invés de alguma outra técnica tradicional, ou uma combinação destas.

Consideram-se, aqui, técnicas tradicionais como métodos de busca que necessitem de um valor inicial para começar o processo de otimização. O ponto ótimo alcançado por estas técnicas é um ótimo local, o que significa que a solução encontrada apenas está próxima da solução inicial. Devido às

UFPA—Universidade Federal do Pará – Departamento de Engenharia Elétrica e de Computação - DEEC, Laboratório de Eletromagnetismo aplicado – LEA AV. AUGUSTO CORRÊA Nº 01 – CP:8619, CEP: 66075-900 BELÉM/PA, BRASIL Marco Jose de Souza, [marcojs@ufpa.br](mailto:marcojs@ufpa.br), Lamartine Villar [lvsouza@nautilus.com.br](mailto:lvsouza@nautilus.com.br), Claudomiro Sales, [claudomiro@yahoo.com](mailto:claudomiro@yahoo.com), João Chamma, [joao\\_chamma@yahoo.com](mailto:joao_chamma@yahoo.com), João Crisostomo, [jweyl@ufpa.br](mailto:jweyl@ufpa.br), C.R. L. Francês, [rfrances@ufpa.br](mailto:rfrances@ufpa.br), Tel +55-91-2111302, Fax +55-91-2111634;

funções envolvidas na maioria dos processos de otimização de dispositivos ópticos serem descontínuas, não lineares e multimodais, o espaço de pesquisa é muito complexo. Essas características testam a robustez de muitas técnicas de otimização tradicionais devido ao pouco conhecimento do espaço de pesquisa. Por isso, para utilizar uma destas técnicas, o ponto inicial deve estar próximo do máximo global, porque de outra forma, podem ficar “presos” a um ótimo local.

Porém, em problemas práticos de otimização de dispositivos ópticos a tarefa de encontrar uma solução inicial é muito difícil ou quase impossível, exigindo em algumas situações uma técnica auxiliar [1]-[2]. Portanto, é recomendado começar a otimização usando uma estratégia estocástica para explorar o espaço de pesquisa. Este trabalho usa o algoritmo genético paralelo que é capaz de encontrar soluções iniciais para estruturas de grades de Bragg em fibra óptica. Os resultados encontrados podem ser usados em técnicas tradicionais de otimização para melhorar a qualidade das soluções encontradas.

A utilização de um programa paralelo se justifica pela necessidade de esforço computacional da técnica de análise de grades no domínio da frequência empregada. Como dentro do GA, essas operações de análise são intensamente utilizadas, o problema de otimização torna-se extremamente oneroso computacionalmente. Sem qualquer paralelização, o tempo de processamento dos programas tornaria a utilização do GA muito difícil. Para a paralelização foi utilizada a MPI (Message Passing Interface) padrão, que permite o uso do programa em diversas plataformas existentes [14].

Este trabalho está dividido da seguinte forma: o item II trata das grades de Bragg e algoritmo genético. O item III descreve o processo de paralelização do algoritmo genético, no item IV são mostrados os resultados obtidos, e por fim a conclusão do trabalho é apresentada.

## II. GRADES DE BRAGG E ALGORITMO GENÉTICO

### A. Algoritmo genético

Os Algoritmos genéticos (GAs) são algoritmos de otimização que simulam a seleção natural e os princípios da genética [3]-[9]. O princípio básico é fazer evoluir um conjunto de soluções iniciais geradas aleatoriamente para a proximidade de um ponto ótimo. Quando o processo de otimização finaliza,

a melhor solução é selecionada e pode ser usada como projeto inicial em técnicas locais de otimização para refinamento desta solução.

Os GAs possuem características que o diferem dos vários métodos de otimização tradicionais, que são as seguintes:

- GAs não trabalham diretamente com os parâmetros de uma função e sim com o código desses parâmetros;
- Este tipo de algoritmo não realiza sua pesquisa a partir de um único ponto (como fazem os métodos tradicionais) e sim a partir de um conjunto de pontos;
- GAs não usam derivadas;
- Algoritmos genéticos utilizam regras de transição probabilística e não regras determinísticas.

Diante dessas características, GAs têm se tornado um método de otimização com grande potencial para resolver problemas onde métodos tradicionais costumam não possuir bom desempenho. Situações como essas ocorrem quando a função a ser otimizada apresenta multiextremos e/ou descontinuidades. Quando a função apresenta multiextremos, o risco de se alcançar um ótimo local é maior. Porém, GAs trabalham a partir de um conjunto de pontos, o que permite que se escape desses ótimos locais com mais facilidade. Quando a função apresenta descontinuidades, GAs apresentam bom desempenho porque não usam derivadas.

Os GAs geralmente tentam alcançar uma solução global de uma função  $f(x)$ , onde  $x$  é definido como  $x=\{x_L|L=1,2,\dots,N\}$ , sendo  $N$  o número de variáveis e  $x_L$  possui valores entre  $x_{Lmin}$  a  $x_{Lmax}$ .

Durante o processo de otimização, GAs utilizam pelo menos três operações básicas: seleção, cruzamento e mutação; que atuando sobre os cromossomos (parâmetros codificados do problema físico) evoluem as soluções para uma solução ótima.

Um importante aspecto dos GAs é a função saúde (ou função objetivo), que calcula a qualidade de uma solução. A função saúde é a conexão entre o problema físico sendo otimizado e o GA. Esta função tem como entrada um cromossomo e produz um número como uma medida do desempenho do cromossomo. Neste trabalho utiliza-se a seguinte função saúde:

$$F(\mathbf{X}) = \left( \frac{1}{p} \sum_{j=1}^p [r(\lambda_j) - r_{opt}(\lambda_j)] / \delta r_j \right)^2 \quad (1)$$

onde  $r(\lambda_i)$  e  $r_{opt}(\lambda_i)$  é o valor obtido pela processo de otimização e o valor desejado, respectivamente.  $\delta r_j$  é um valor de tolerância da variável  $\lambda_j$ , e  $p$  é o número de amostras da função que está sendo otimizada.

**B. Grades de Bragg**

Neste trabalho consideraram-se apenas as grades de Bragg em fibras (Fiber Bragg Grating - FBG) nos quais o acoplamento ocorre entre modos propagantes em direções opostas. A

análise de tais estruturas pode ser realizada de acordo com procedimento apresentado em [10], no qual, a partir das equações de modos acoplados e da chamada “aproximação síncrona” para grades de Bragg em fibra, obtêm-se os valores dos coeficientes de acoplamento, descritos por :

$$k = k^* = \frac{\pi}{\lambda} v \bar{\delta}_{neff} \quad (2)$$

$$\hat{\sigma} = \delta + \sigma - \frac{1}{2} \frac{d\phi}{dz} \quad (3)$$

$$\sigma = \frac{2\pi}{\lambda} \bar{\delta}_{neff} \quad (4)$$

Nas expressões (1)-(3)  $\delta$  representa o fator de sintonia da grade,  $k$  representa o termo “AC” do coeficiente de acoplamento e  $\bar{\sigma}$  o termo “dc” do coeficiente geral de auto-acoplamento. O valor médio da variação de índice calculado ‘especialmente ao longo de um período da grade ( $\Lambda$ ) é descrito por  $\bar{\delta}_{neff}$ . O valor médio do coeficiente de acoplamento calculado ao longo do período é dado por  $\sigma$ ;  $\phi$  é a modulação no período da grade ao longo do eixo da fibra e  $v$  é a visibilidade de franja da variação do índice.

As grades não uniformes podem ser modeladas utilizando-se o método matricial, no qual a grade é dividida em  $M$  seções uniformes, sendo cada seção representado por uma matriz  $2 \times 2$ . A Fig. 1 mostra a aplicação deste método.

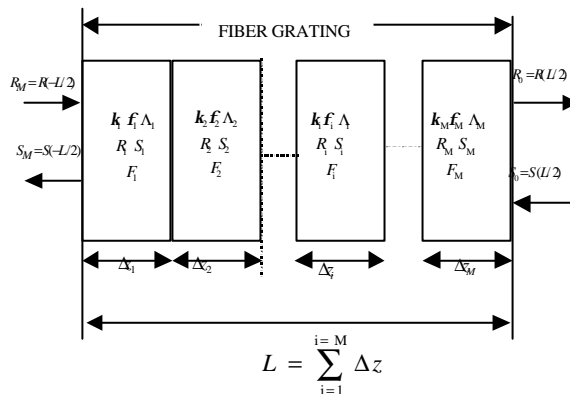


Fig. 1. Divisão da grade de Bragg em M seções uniformes

Definindo-se  $R_i$  e  $S_i$  como as amplitudes de campo nas fronteiras de cada seção uniforme  $i$  e considerando as condições de contorno  $R_0 = R(L/2) = 1$  e  $S_0 = S(L/2) = 0$ , calcula-se  $R(-L/2) = R_M$  e  $S(-L/2) = S_M$ . A propagação através de cada seção uniforme  $i$  é descrita por uma matriz  $F_i$  definida por:

$$\begin{bmatrix} R_i \\ S_i \end{bmatrix} = F_i \begin{bmatrix} R_{i-1} \\ S_{i-1} \end{bmatrix} \quad (5)$$

Para grades de Bragg a matriz  $F_i = F_iB$  é dada abaixo [10]:

$$F_i^B = \begin{bmatrix} \cosh(\gamma_B \Delta z) - i \frac{\bar{\sigma}}{\gamma_B} \sinh(\gamma_B \Delta z) & -i \frac{\kappa}{\gamma_B} \sinh(\gamma_B \Delta z) \\ i \frac{\kappa}{\gamma_B} \sinh(\gamma_B \Delta z) & \cosh(\gamma_B \Delta z) + i \frac{\bar{\sigma}}{\gamma_B} \sinh(\gamma_B \Delta z) \end{bmatrix} \quad (6)$$

sendo  $\Delta z$  o comprimento da  $i$ -ésima seção uniforme, os coeficientes de acoplamento  $\bar{\sigma}$  e  $\kappa$  são os valores locais na  $i$ -ésima seção, e

$$\gamma_B = \sqrt{\kappa^2 - \bar{\sigma}^2} \quad (7)$$

Uma vez que todas as matrizes para seções individuais são conhecidas, encontram-se as amplitudes de saída dadas por [10]:

$$\begin{bmatrix} R_M \\ S_M \end{bmatrix} = F \begin{bmatrix} R_0 \\ S_0 \end{bmatrix}; F = F_M \cdot F_{M-1} \cdot \dots \cdot F_1 \cdot \dots \cdot F_1 \quad (8)$$

O número de seções necessárias para cálculo utilizando o método de seções uniformes é determinado pela precisão exigida. Para muitas grades apodizadas e moduladas,  $M$  sendo aproximadamente igual a 100 seções é suficiente.  $M$  não pode ser arbitrariamente grande, já que a aproximação pela teoria de modos acoplados não é válida quando uma seção de grade uniforme contém apenas uns poucos períodos da grade. Portanto, deve-se respeitar a condição:

$$M \ll \frac{2n_{\text{eff}}L}{\lambda_D} \quad (9)$$

### III. PROCESSAMENTO PARALELO

A paralelização é uma estratégia utilizada em computação para se obter resultados mais rápidos de grandes e complexas tarefas. Uma grande tarefa pode ser executada serialmente ou concorrentemente, dividida em partes da seguinte forma:

- Identificam-se tarefas menores no interior da tarefa maior a ser paralelizada;
- Distribuem-se as pequenas tarefas por entre vários "trabalhadores", que irão executá-la simultaneamente;
- Coordenam-se os "trabalhadores".

Para se decompor um programa em pequenas tarefas a serem executadas em paralelo, primeiro é necessário distinguir a decomposição funcional da decomposição de domínio. Na primeira, o problema é decomposto em diferentes tarefas que serão distribuídas por entre múltiplos processadores para execução simultânea. Essa técnica é adequada a um programa dinâmico e modular. Cada tarefa será um programa diferente. Na decomposição de domínio, os dados são decompostos em grupos que serão distribuídos por entre múltiplos processadores que executarão, simultaneamente, um mesmo

programa.

Seja qual for a forma de decomposição escolhida, deve-se garantir o balanceamento de carga. A distribuição das tarefas por entre os processadores deverá ser sempre de maneira tal que o tempo da execução das partes seja o mais próximo possível. Se essa exigência não for satisfeita, o desempenho do programa paralelo será menor, pois frequentemente ocorrerão processos inativos aguardando parâmetros de alguma outra tarefa obrigatória em curso. Para o problema de paralelização do GA em questão, o balanceamento de carga é algo relativamente simples de se resolver. Como o processamento é proporcional ao número de indivíduos da população, a paralelização através da distribuição de partes de tamanhos iguais da população garante a mesma carga para todas as máquinas utilizadas no processamento da tarefa. Isso, obviamente, apenas se todas as máquinas envolvidas possuírem capacidades computacionais similares.

A paralelização foi realizada com o MPI (Message Passing Interface), utilizando a implementação MPI LAM versão 1.2.4 criada na Universidade de Indiana. A estratégia de paralelização do algoritmo genético foi baseada na decomposição de domínio, ou seja, os dados foram decompostos em grupos e distribuídos entre os processadores que executam o mesmo programa simultaneamente [13][14].

Uma vez que praticamente toda carga computacional está no cálculo de saúde de cada indivíduo, esta tarefa foi escolhida para ser paralelizada.

Como pode ser observado na Fig. 2, o GA não é executado completamente nos computadores escravos. A tarefa do mestre é praticamente igual a que seria se não houvesse paralelização alguma. Porém, em vez de calcular a saúde de toda a população, o mestre calcula apenas para uma parte. A população restante é dividida e cada parte é enviada para um computador escravo correspondente. Cada escravo analisa sua parte da população e retorna, para o processo mestre, uma tabela de valores de saúde. O processo mestre agrupa as tabelas de saúde coletadas na forma de um único vetor, o qual é utilizado para dar prosseguimento ao GA.

O cluster utilizado, isto é, o conjunto de computadores destinados à execução da tarefa paralela, consiste em 7 estações (AMD Athlon 1800 MHz e 1.5 GB de memória RAM) e 1 estação (AMD Athlon 1800 MHz com processador duplo e 3.0 GB de memória RAM). Como todas as estações apresentam processadores iguais (cluster homogêneo), o balanceamento de carga foi resolvido através da divisão da população em partes iguais.

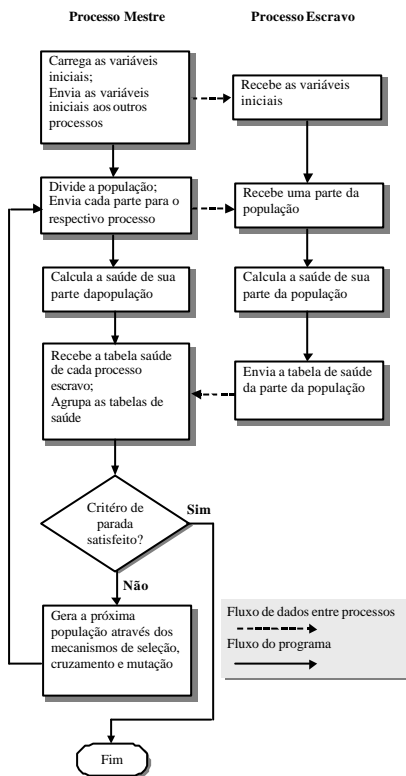


Fig. 2. Fluxograma do programa paralelo. O critério de parada pode ser baseado em um número limite de

#### IV. RESULTADOS

Neste trabalho apresenta-se a otimização de dois projetos de grades de Bragg não uniformes.

O primeiro projeto a ser otimizado é a grade de Bragg com refletividade máxima ( $r=1$ ) na faixa de  $1550.2 \leq \lambda \leq 1550.6$  e nula ( $r=0$ ) fora dessa região. Neste projeto utilizaram-se 1000 comprimentos de ondas equidistantes de amostras para  $p$  em (11). Os parâmetros utilizados para a grade foram os seguintes: comprimento  $L = 1\text{cm}$ , índice efetivo  $n_{eff} = 1.45$ , visibilidade de franja  $v = 1$  e o comprimento de onda de projeto  $\lambda_D = 1550\text{ nm}$ . As restrições impostas são  $10 \cdot 10^{-5} \leq \Delta z_i \leq 10^{-3}$  e  $0.0 \leq \delta n_{eff} \leq 4 \cdot 10^{-4}$  e  $\delta r = 0,01$  para todos os comprimentos de onda. A refletividade e o perfil para  $\delta n_{eff}$  são mostradas nas Fig. 3 e 4, respectivamente. As Fig. 5 e 6 mostram o atraso de grupo versus comprimento de onda e a evolução do GA, respectivamente.

Este resultado pode ser um projeto inicial para refinamento por técnicas tradicionais de otimização

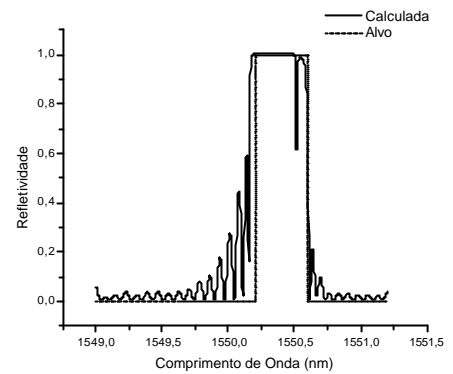


Fig. 3. Refletividade calculada para a grade de fibra com  $6 \cdot 10^{-5} \leq \Delta z_i \leq 10^{-3}$  e  $0.0 \leq \delta n_{eff} \leq 4 \cdot 10^{-4}$  dentro da região espectral de  $1550.2 \leq \lambda \leq 1550.6\text{ nm}$




Fig. 4. O perfil para  $\delta n_{eff}$ .




Fig. 5. Atraso de grupo versus comprimento de onda

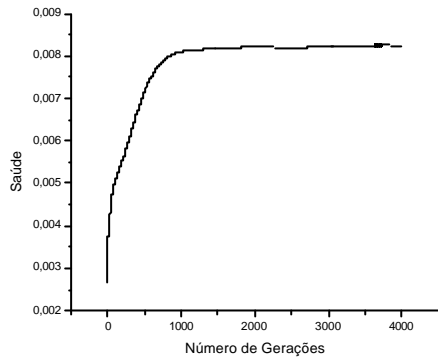


Fig. 6. Curva de evolução do GA.

O segundo projeto é a grade de Bragg com refletividade máxima na faixa de  $1550.0 \leq \lambda \leq 1550.2$  e nula ( $r=0$ ) fora dessa região, permanecendo os demais parâmetros da grade do projeto anterior. As restrições impostas são  $5.34 \times 10^{-5} \leq \Delta z_i \leq 10^{-3}$  e  $0.0 \leq d_{neff} \leq 1.5 \times 10^{-4}$ . A refletividade e o perfil para  $d_{neff}$  são mostradas nas Fig. 7 e 8, respectivamente. As Fig. 9 e 10 mostram o atraso de grupo versus o comprimento de onda e a evolução do GA, respectivamente.




Fig. 7. A refletividade calculada para a grade de fibra com  $5.34 \times 10^{-5} \leq \Delta z_i \leq 10^{-3}$  e  $0.0 \leq d_{neff} \leq 1.5 \times 10^{-4}$  dentro da região espectral de  $1550 \leq \lambda \leq 1550.2$  nm




Fig. 8. O perfil do  $d_{neff}$ .

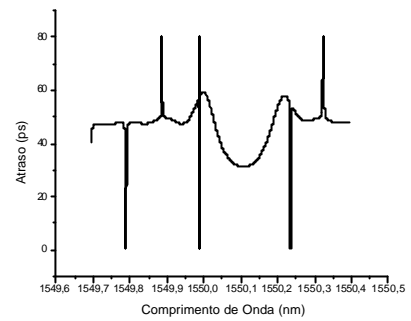


Fig. 9. Atraso de grupo versus comprimento de onda

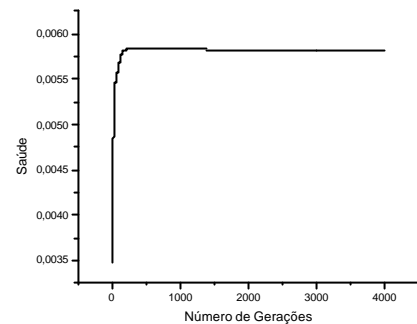


Fig. 10. Curva de evolução do GA

Para analisar os efeitos da paralelização, os tempos de processamento para os dois dispositivos, utilizando 1, 3, 4 e 8 processadores, foram reunidos na Tabela 1. Através dessa tabela percebe-se a significativa redução nos tempos de processamento seriais a medida que mais processadores são utilizados pelo cluster [14]. Entretanto, o aumento do desempenho computacional pode ser melhor observado através de uma medida conhecida como speedup.

A speedup é a relação entre o tempo de processamento serial (utilizando apenas 1 processador) e o tempo de processamento paralelo [14]. O valor obtido dessa relação deve ser o mais próximo possível do número de processadores utilizados: quanto mais próximo for, maior será a eficiência da paralelização obtida. A eficiência de paralelização é a relação entre o speedup e o número de processadores utilizados. A Tabela 2 mostra os valores de speedup e eficiência médios para 1, 3, 4 e 8 processadores

TABELA 1  
TEMPO DE PROCESSAMENTO

Número de processadores	Tempo médio (s)	
	Dispositivo 1	Dispositivo 2
1	121811	121710
3	41365	41365
4	31126	31082
8	15585	15614

TABELA 2  
SPEEDUP E EFICIÊNCIA DE PARALELIZAÇÃO

Número de processadores	Speedup médio	Eficiência %
1	1	100
3	2.950172	98.33906586
4	3.914626	97.86564847
8	7.80542	97.56775229

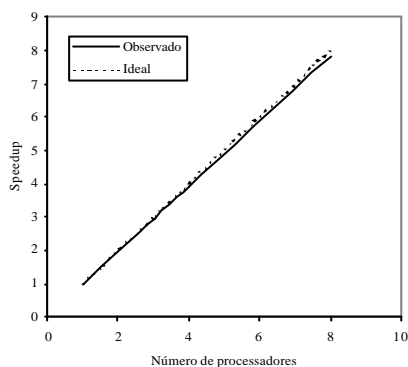


Fig. 11. Curva de speedup real e ideal.

A Fig. 11 mostra a curva de speedup em função do número de processadores utilizados. A proximidade entre a curva obtida e a curva ideal evidencia a “granularidade grossa” apresentada pelo problema. “Granularidade grossa” significa que mais operações de computação são realizadas do que operações de comunicação. Ou seja, quanto maior (mais “grossa”) for a granularidade do problema, maior será a possível eficiência de paralelização, bem como o desempenho geral do programa paralelo. Embora as operações de comunicação sejam mais freqüentes proporcionalmente ao número de processadores, esse fato não chegou a afetar consideravelmente a eficiência de paralelização, como visto na Tabela 2 [14].

## V. CONCLUSÕES

Neste trabalho foram apresentados dois projetos de grades de Bragg em fibra usando processamento paralelo e algoritmo genético. Os resultados mostraram que GAs é uma técnica de otimização global e robusta, e é adequada para utilização em problemas com espaço de buscas complexos. Entretanto, embora o GA seja um método de busca extremamente aplicável na otimização de grades de Bragg, sua utilização é muito restrita pela intensa capacidade computacional requerida. Certos problemas podem exigir tanto tempo de processamento a ponto da aplicação de um GA tornar-se inviável, quando

comparado a outras técnicas que, mesmo menos robustas, são capazes de obter resultados em tempos mais confortáveis.

Foi mostrado que a paralelização torna os GAs aplicados na síntese de grades totalmente viável, ainda mais pelas próprias características especiais que naturalmente apresentam. Devido operarem com populações de soluções, foi simples balancear a carga do programa paralelo, sendo ainda possível adaptá-lo até mesmo para clusters não homogêneos. Devido a operação de cálculo de saúde ser a única parte do programa serial dispendiosa em termos computacionais, bastou dividir o programa serial nesse ponto para torná-lo paralelo com uma eficiência de quase 100%.

A mesma metodologia de paralelização utilizada neste trabalho pode ser utilizada em outros problemas que apresentem funções de cálculo de saúde computacionalmente exigentes.

## REFERÊNCIAS

- [1] J. A. Dobrowolski e R. A. Kemp, "Refinement of optical systems with different optimization procedures," *App. Opt.* 29, pp. 2876-2893, 1990
- [2] P. Baumeister, "Starting designs for the Computer Optimization of Optical Coatings," *App. Opt.* 34, pp. 4835-4843, 1995.
- [3] D. E. Goldberg, *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison-wesley, New York, 1989.
- [4] K.S. Tang, K. F. Man, S. Kwong and Q. HE, "Genetic Algorithms and their Applications," *IEEE Signal Processing Magazine*, 13, pp 22-37, 1996
- [5] J. M Johnson and Yahya, "Genetic Algorithms in Engineering Electromagnetics," *IEEE Antennas Propagat. Magazine.*, 39, pp 7-25, 1997.
- [6] R. L. Haupt, "Thinned arrays using genetic algorithms," *IEEE Trans. Antennas Propagat.*, 42, pp. 993 – 999, 1994.
- [7] R. L. Haupt, J. J. Menozi, e C. J. McCormack, "Thinned arrays using genetic algorithms," in *Proc. IEEE Antennas Propagat. Soc. Int. Symp.*, pp. 712 – 715, Ann Arbor, MI, 1993.
- [8] R. L. Haupt, "An Introduction to Genetic Algorithms for Electromagnetics," *IEEE Antennas Propagat. Magazine*, 37, pp 7–15, 1995
- [9] D. S. Weile e E. Michielssen, "Genetic Algorithm Optimization Applied to Electromagnetics: A Review," *IEEE Trans. Antennas Propagat.*, 45, pp. 343 – 353, 1997.
- [10] T. Erdogan, "Fiber Grating Spectra," *IEEE. J. Lightwave Technology.*, 15, pp. 1277 – 1294, 1997.
- [11] M. Yamada and K. Sakuda, "Analysis of almost-periodic distributed feedback slab waveguide via a fundamental matrix approach," *App. Opt.* 26, pp 3474-3478, 1987.
- [12] H. Kogelnik, *Guided –Wave Optoelectronics*, Springer Verlag, New York, 1990.
- [13] Y. Foster, K. Kennedy, J. Dongarra, G. Fox. *Sourcebook of Parallel Computing*, Morgan Kaufman Pub, 2002.
- [14] W. Gropp, E. Lusk, A. Skjellum, R. Thakur. *Using MPI : Portable Parallel Programming with the Message Passing Interface (Scientific and Engineering Computation)*, 2nd Edition, MIT Press, 1999.