

ALGORITMOS GENÉTICOS COMO FERRAMENTA AUXILIAR NA TOMADA DE DECISÃO EM ATIVIDADES DE GESTÃO AGROINDUSTRIAL

Danilo Augusto Heredia VIEIRA¹

Celso Correia de SOUZA²

José Francisco dos REIS NETO³

Resumo. As programações linear e não-linear, ramos da matemática aplicada, tem auxiliado administradores de empresas no processo de gestão agroindustrial, permitindo que uma decisão seja simulada e analisada exaustivamente antes da sua implementação prática. Existem vários aplicativos clássicos na literatura que solucionam tais problemas. Mais recentemente surgiram os Algoritmos Genéticos que propiciam soluções eficientes de problemas de programação linear e não-linear, não requerendo nenhuma exigência sobre a derivabilidade das funções envolvidas. O objetivo desse trabalho de pesquisa foi testar a utilização dos Algoritmos Genéticos na solução de problemas de programação linear e não-linear aplicados à gestão agroindustrial. Dois exemplos foram resolvidos. O primeiro tratou da solução de um problema de programação linear inteira e o segundo de um problema de programação não-linear, ambos aplicados à gestão agroindustrial. Os resultados podem ser considerados bons, com soluções iguais às obtidas utilizando-se o consagrado aplicativo *Solver* do *Excel*, que possui limitações quanto ao número de variáveis dos problemas e da continuidade das funções envolvidas em problemas de programação não-linear.

Palavras-chave: corte de cana-de-açúcar, pesquisa operacional, rendimento econômico.

¹ Acadêmico do 7º semestre do curso de Administração da Universidade Anhanguera- Uniderp de Campo Grande – MS. daniloahv@hotmail.com. Bolsista PIBIC/CNPq.

¹ Professor do Programa de Mestrado em Produção e Gestão Agroindustrial da Universidade Anhanguera-Uniderp de Campo Grande – MS. celsouza@yahoo.com.br

³ Professor do Curso de Administração da Universidade Anhanguera-Uniderp de Campo Grande – MS. Doutorando em Economia e Administração pela Universidad de Salamanca, Espanha. jfrn@terra.com.br

1 INTRODUÇÃO

O agronegócio é um conjunto de operações que envolve as atividades de produção e armazenamento no campo, bem como transporte, processamento e distribuição dos produtos agropecuários e seus derivados, além da distribuição de insumos e a disseminação de novas tecnologias agropecuárias. Essas operações estão, de certa forma, interligadas formando as cadeias produtivas de alimentos, fibras e também de biomassa para silagem e geração de energia.

No agronegócio diversos fatores como variações nos preços de mercado, alterações climáticas, instabilidade das políticas econômicas e agrícolas e dificuldade de acesso às novas tecnologias ou às redes de informações, alheios ao controle do produtor, podem ocorrer e interferir nas atividades agropecuárias, dificultando a elaboração e implementação de qualquer plano de negócio.

A utilização das ferramentas computacionais no agronegócio vem crescendo continuamente, impulsionada pela necessidade de obter melhor produtividade e rentabilidade. A necessidade da implantação de técnicas alternativas, equipamentos e recursos que beneficiem o planejamento e o controle do processo produtivo ocorrem em razão do aumento de competitividade no setor.

O planejamento agroindustrial é uma atividade de importância fundamental para a obtenção de bons resultados, sendo feito através da elaboração do conjunto de metas que se pretende atingir, e das técnicas e recursos disponíveis para se chegar até elas. Com isso, é possível antever com precisão os resultados de estratégias de ação, bem como detectar e corrigir possíveis falhas durante sua execução.

A programação linear e não-linear são modelos matemáticos que auxiliam os empresários nas tomadas de decisão, na medida em que constituem idealizações simplificadas da realidade, que emprega símbolos matemáticos para representar as variáveis de decisão do sistema real.

Existem vários softwares que possuem rotinas consagradas para a resolução de problemas de programação linear e não-linear. Nos métodos iterativos clássicos podem ocorrer problemas de convergência na solução de problemas não-lineares,

quando a função objetivo contém pontos onde não é derivável ou o valor da derivada está muito próxima de zero.

Mais recentemente surgiram os Algoritmos Genéticos que, além de resolver problemas de programação linear e não-linear, não estão atrelados a problemas específicos de derivadas de funções.

O objetivo desse trabalho foi à aplicação de Algoritmos Genéticos na tomada de decisão no planejamento de um agronegócio visando o maior retorno econômico e atendendo determinadas limitações dessa atividade.

2 FUNDAMENTAÇÃO TEÓRICA

2.1. Programação linear e não-linear

Problemas de otimização, na sua forma geral, têm como objetivo maximizar ou minimizar uma função definida sobre um certo domínio. Na teoria clássica de otimização o valor ótimo é obtido sobre um domínio infinito.

Já no caso dos chamados problemas de otimização combinatória, o domínio é tipicamente finito, em que é possível listar os seus elementos e também testá-lo se pertence ou não a esse domínio. O teste de todos os elementos deste domínio se torna inviável, principalmente quando o domínio é de tamanho de moderado a grande (Miyazawa, 2009).

Problemas de programação linear e não-linear são problemas de otimização clássica que envolvem a maximização ou minimização de funções num domínio infinito, normalmente definido por um conjunto de restrições, como na expressão (01) (Caixeta Filho et al., 2000 ; Bregalda et al., 1988).

$$\begin{array}{l} \text{Otimizar} \quad f(x) \\ \text{sujeito à} \quad \begin{cases} g_i(x) =, \leq, \geq b_i \\ x_j \geq 0 \end{cases} \end{array} \quad (01)$$
$$i = 1, 2, \dots, m$$
$$j = 1, 2, \dots, n$$

sendo $f(x)$ a função a ser otimizada (maximizada ou minimizada); $g_i(x)$, ($i = 1, 2, \dots, m$), restrições do modelo, que relacionam os recursos disponíveis; x_j ,

($j = 1, 2, \dots, n$), variáveis de decisão do problema (são as incógnitas do problema); $b_i \in \Re$, ($i = 1, 2, \dots, m$), níveis de disponibilidade de recursos ou quantidade mínima a ser suprida. *Otimizar* engloba os problemas de maximização e minimização.

Quando as funções $f(x)$ e $g_i(x)$, ($i = 1, 2, \dots, m$), são funções lineares, diz-se que o sistema (01) é Problema de Programação Linear; se $f(x)$ ou ao menos uma das funções $g_i(x)$, ($i = 1, 2, \dots, m$), é uma função não-linear, diz-se que o sistema (01) é Problema de Programação não-linear (Hillier e Lieberman, 1988).

Existem vários aplicativos para a solução de problemas de programação linear e não-linear, disponíveis para microcomputadores, entre eles, a ferramenta *Solver* do aplicativo *Microsoft Excel®* é, certamente, o de mais fácil acesso, devido a popularidade desta planilha eletrônica, possibilitando acesso à maioria dos leitores que usam microcomputadores (Loesch e Hein, 1999).

A solução de problemas de programação não-linear ser obtida utilizando-se recursos do Cálculo Diferencial, através do método direto e iterativos, desde que as funções $f(x)$ e $g_i(x)$, ($i = 1, 2, \dots, m$) sejam deriváveis no seu domínio de solução (Hillier e Lieberman, 1988). Quando isso não acontece, os Algoritmos Genéticos podem auxiliar na resolução, pois são métodos que podem lidar com qualquer problema de otimização, não estando atrelados, por exemplo, a problemas específicos de derivadas (Linden, 2008; Miranda, 2009).

2.2. Algoritmos genéticos

Algoritmos Genéticos são algoritmos de busca estocásticos que têm desenvolvimento e funcionamento vinculados à genética, em que todas as novas espécies são produzidas por meio de uma seleção natural em que o mais apto sobrevive gerando descendentes.

O algoritmo genético básico é o que realiza as seguintes funções: inicializa a população de cromossomos; avalia cada cromossomo da população; cria novos cromossomos a partir da população atual (realiza cruzamento e mutação); e termina, se o critério de fim for alcançado, se não, reinicializa (Bittencourt, 1998; Holland, 1975; Santa Catarina & Bach, 2003).

Na forma analógica, a implementação dos Algoritmos Genéticos parte de uma população indivíduos gerados aleatoriamente (configurações iniciais de um

problema), realiza-se a avaliação de cada um (em relação a função objetiva), seleciona os mais aptos e promove os manipuladores ou operadores genéticos como cruzamento e mutação, originando novas gerações de indivíduos.

Cada indivíduo na população representa uma possível solução para um dado problema, o que o Algoritmo Genético faz é buscar aquela solução que seja muito boa ou a melhor do problema analisado através da criação de população de indivíduos cada vez mais aptos levando à otimização da função objetiva. Na Figura 1 é possível resumir os Algoritmos Genéticos através do fluxograma.

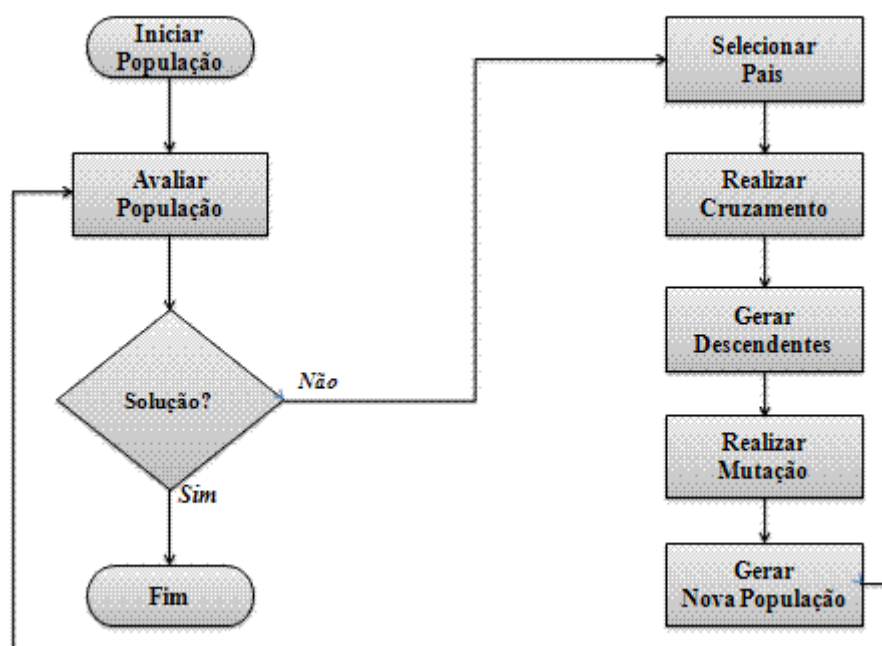


Figura 1. Fluxograma da solução de problemas de otimização com Algoritmos Genéticos

A aplicação dos Algoritmos Genéticos, como descrito pelo fluxograma da Figura 1, consta dos seguintes passos (Alencar e Corrêa, 2006; Guervós, 2009; Linden, 2008; Viana, 1998; Pacheco, 2009):

Escolha da População - a inicialização da população é feita da forma mais simples possível, fazendo-se uma escolha aleatória independente para cada indivíduo da população inicial ou por processo heurístico, isto é, simplesmente escolher n indivíduos dentro do espaço de busca. Essa técnica permite gerar uma boa distribuição, cobrindo um espaço maior no espaço de busca, sem interessar se

são boas soluções ou não, assim como na natureza, para haver evolução é necessário diversidade.

Avaliação - a função de avaliação, ou função objetiva, é utilizada para determinar a qualidade de um indivíduo como solução do problema, ou seja, é uma forma de mensurar quão aptos estão os indivíduos da população. A função de avaliação deve refletir os objetivos a serem alcançados na resolução de um problema e é derivada diretamente das condições impostas pelo problema;

Seleção - a seleção dos indivíduos da população deve simular o mecanismo de seleção natural, “sobrevivência dos mais fortes”, em que os pais mais aptos geram mais filhos. O algoritmo permite, também, que alguns indivíduos menos aptos gerem filhos, garantindo a diversidade entre os indivíduos melhores e os piores. Se apenas os melhores indivíduos se reproduzirem a população tenderá a ser cada vez mais semelhante, não ocorrendo a evolução.

Há diversas formas de seleção dos indivíduos reprodutores, entre elas as mais usadas são os métodos de seleção por Torneio e pelo método da Roleta Viciada;

Seleção Via Método da Roleta Viciada - este método emprega o princípio da probabilidade de sobrevivência do mais apto, ou seja, que possui a melhor função objetiva associada. Com base nos valores de $f_i(x_i)$, onde x_i é o indivíduo i avaliado entre os n indivíduos amostrados.

Os indivíduos mais aptos são selecionados e duplicados em substituição aos menos aptos. Neste método, a probabilidade p_i do i -ésimo indivíduo da população vir a ser selecionado é dado pela expressão (02).

$$p_i = \frac{f_i}{\sum_{i=1}^n f_i} \quad (02)$$

Neste método, os indivíduos com alta aptidão recebem uma proporção maior na roleta e os indivíduos com baixa aptidão uma porção relativamente menor na roleta. Na Figura 2 estão dispostos 4 pais, A1, A2, A3 e A4, com as suas respectivas aptidões (áreas dos setores circulares), para serem selecionados através da roleta e gerarem uma nova população. Observa-se que o indivíduo A1 tem maiores chances de ser escolhido ao rodar a roleta.






Figura 2 Seleção de indivíduos através da roleta viciada

O ato de rodar a roleta deve ser completamente aleatório, podendo ser simulado escolhendo-se um número aleatório “r” no intervalo [0, 1] e comparar seu valor com a probabilidade acumulada q_i , considerando $q_0 = 0$, expressão (03). Assim, se $q_{i-1} < r \leq q_i$ deve-se selecionar o indivíduo x_i .

$$q_i = \sum_{k=0}^i p_k \quad (03)$$

Este método tem a desvantagem de possuir uma alta variância, podendo levar a um grande número de cópias de um bom cromossomo, diminuindo a diversidade da população, podendo causar uma convergência prematura do algoritmo para uma solução não almejada.

Quando a evolução está avançada, em que as aptidões não diferenciam entre si, pode causar um estagnação do algoritmo, isto é, pouca modificação na seleção dos indivíduos;

Elitismo - o elitismo visa preservar os melhores cromossomos de uma geração para outra sem alterações, garantindo sempre que a melhor solução encontrada em qualquer uma das gerações seja mantida até o final do processo. Geralmente usa-se nos Algoritmos Genéticos uma taxa de elitismo de 30% do total de indivíduos gerados.

A principal vantagem deste método é que a convergência é garantida, isto é, se o máximo global for descoberto, AG converge para esse máximo, entretanto, da mesma forma existe o risco da estagnação em um máximo local.

Neste trabalho de pesquisa utilizou-se Algoritmos Genéticos Binários, em que os pontos do espaço de solução são codificados como uma cadeia de bits 0 ou 1, dentro de cada indivíduo. Cada bit poderia ser considerado um gene do cromossomo ou indivíduo. A escolha dos Algoritmos Genéticos Binários se prende à facilidade de se efetuar os cruzamentos e as mutações entre os indivíduos.

Cruzamento - o cruzamento ou *crossover* é em processo de recombinação de partes das seqüências de caracteres entre pares de cromossomos, com o objetivo de gerar nova descendência. Esta troca de material genético garante a recombinação da população, possibilitando, assim, uma probabilidade maior de produzir indivíduos mais evoluídos que seus pais.

Para maior facilidade de se efetuar os cruzamentos e as mutações, a população de números decimais de ser transformada para a base 2.

Um Ponto de Corte - esta é a forma mais simples de cruzamento, e que foi utilizada neste trabalho, onde dois indivíduos da população, após a seleção, são submetidos ao processo de cruzamento, no qual o ponto de corte é aleatoriamente gerado, os caracteres ou bits que precedem o ponto de corte são preservados, e os bits posteriores são trocados entre o par participante do processo (Figura 2).

Mutação - este operador é responsável pela introdução e manutenção da diversidade genética na população. O operador de mutação inverte os valores de bits, ou seja, muda o valor de dado bit de 1 para 0 ou de 0 para 1, com o objetivo de tentar regenerar algum indivíduo que possa ter sido eliminado de forma inesperada.

Para que uma determinada população não sofra muitas alterações, esta operação é processada para um pequeno percentual PM de seus elementos, em torno de 1% de todos os genes.

Após as operações de cruzamento e mutação, com a obtenção de uma nova população, esta deve ser avaliada nos novos pontos do espaço de busca, com a conversão da população para números decimais, através da expressão (04),

$$x = l_{\text{inf}} + \frac{(L_{\text{Sup}} - l_{\text{inf}})}{2^{\text{nbits}} - 1} b_{10} \quad (04)$$

onde l_{inf} e L_{Sup} são, respectivamente, os limites inferior e superior do intervalo de busca, b_{10} é o número decimal, gerado aleatoriamente dentro do intervalo obtido

através da precisão estabelecida, não necessariamente pertencente ao espaço de busca de otimização.

Se a solução atual não satisfizer a precisão adotada, repete-se os passos anteriores para a nova população gerada.

3 MATERIAL E MÉTODOS

Neste trabalho utilizou basicamente o método descritivo exploratório, que consistiu numa pesquisa bibliográfica sobre os modelos matemáticos de programação linear e não-linear e seus métodos clássicos de resolução, bem como sobre Algoritmos Genéticos, objeto principal desse trabalho, que é um método bem recente para a resolução desses modelos matemáticos.

Como objetos da pesquisa foram apresentados dois estudos de casos. O primeiro trata de um criador de frangos de corte que quer fornecer uma ração balanceada para sua criação, combinando apenas necessidades protéicas e calóricas. Admite-se que a ração ótima para estes animais necessita ter, no mínimo, 17,16% de proteína e 3000 quilocalorias (Kcal) de energia metabolizável aparente. Sabe-se que o criador tem disponíveis apenas milho e farelo de soja e que cada quilograma de milho contém 8,51% de proteína e 3146 Kcal de energia. O farelo de soja, por sua vez, contém 45,6% de proteína e 2283 Kcal de energia por quilograma, mas tem-se disponível apenas 0,2 kg de farelo de soja para cada porção de ração.

A função objetiva (05) a ser minimizada, deve considerar que o preço do milho será de R\$0,80/kg e o do farelo de soja, R\$3,80/kg. Assim, a função $C(x, y)$ está ligada ao custo final da ração, resultado da interação entre a quantidade de milho (x), e de farelo de soja (y), multiplicando-se pelos seus custos, respectivamente.

$$C(x, y) = 0,8x + 3,8y \quad (05)$$

Algumas restrições (06) devem ser respeitadas para que o resultado seja o ideal.

$$\text{sujeito à } \begin{cases} 0,0851x + 0,456y \geq 0,1716 \\ 3146x + 2283y \geq 3000 \\ y \leq 0,2 \\ x \geq 0 \\ y \geq 0 \end{cases} \quad (06)$$

Será utilizado o aplicativo *Solver* na solução desse problema, mas o objetivo principal é resolvê-los utilizando-se Algoritmos Genéticos e estabelecer comparações.

O segundo estudo de caso trata da obtenção do maior rendimento de produção de uma empresa que dispõe, sem restrição, de quantidades variáveis de insumo e mão de obra. Tem-se, também, os custos desses insumos e mão-de-obra na elaboração de cada unidade de produto.

A receita $z = R(x, y)$ é dada por uma expressão matemática, obtida empiricamente pelo setor econômico da empresa, que relaciona capital e mão-de-obra, indicando que serão produzidas x unidades de um produto A e y unidades de um produto B. A função $R(x, y)$, de domínio \mathfrak{R}^2 , deve ser maximizada sem nenhuma restrição, expressão (08).

$$\text{Máx } z = R(x, y) \quad (07)$$

Para a solução desse segundo caso utilizar-se-á o método direto clássico, Algoritmos Genéticos e o aplicativo *Solver*, estabelecendo-se comparações entre eles.

4 RESULTADOS E DISCUSSÃO

O primeiro caso trata-se de um criador de frangos de corte que pretende fornecer uma ração balanceada à seus animais. O que se pretende é fornecer uma mistura rica em proteínas e em valores energéticos, a fim de ter um maior rendimento de crescimento com um menor custo da ração.

A entrada de dados foi através de uma planilha Excel com os dados de proteínas, energia e o custo, respectivos.

Tabela 1. Dados referentes às restrições que o criador deve respeitar para conseguir a melhor solução da mistura.

	Milho(%)	Farelo de soja(%)	Necessidades Mínimas(%)
Proteína	8,51	45,6	17,17
Energia(Kcal)	3146	2283	3000
Custo(\$)	0,8	3,8	

Fonte: (FERREIRA,1999)

Com a utilização dos Algoritmos Genéticos, chegou-se a uma solução ótima da mistura desejada. Foram encontrados os valores referentes à quantidade necessária de Milho (x) e de Farelo de soja (y).

Tabela 2. Resultados referente às quantidades necessárias e ideal de Milho (x), de Farelo de soja (y) e do custo total $C(x, y)$.

X	Y	$C(x, y)$
0,9444	0,2	1,51

Esse sistema também foi resolvido com a utilização da ferramenta *Solver* do Excel, obtendo-se os mesmos resultados explicitados na Tabela 2, permitindo comprovar a eficiência da resolução aplicando Algoritmos Genéticos, que, embora mais demorado do que a ferramenta *Solver*, é justificada a sua aplicação levando-se em conta a limitação dessa ferramenta quanto ao número de variáveis de decisão (aproximadamente 200 variáveis para o MS_Excel 2003), limitação superada pelos Algoritmos Genéticos.

O segundo caso trata-se de uma função $R(x, y)$ de duas variáveis x e y , não-linear, denominada de função receita, numa unidade monetária qualquer, a ser maximizada nessas duas variáveis, podendo x representar o número de unidades a ser produzida de um produto A e y o número de unidades a ser produzida de um

produto B. A expressão de $R(x, y)$ foi determinada de maneira empírica no Departamento de Marketing da empresa, sendo dada pela expressão (08), com

$$R(x, y) = 32x + 20y + 3xy - 2x^2 - 2,5y^2$$

Resolvido o problema de máximo utilizando-se o método direto, encontrou-se $R_{\text{máx}}(20,16) = 480$. Assim, devem ser produzidas 20 unidades do produto A e 16 unidades do produto B, aferindo-se uma receita máxima de 480 unidades monetárias.

Para a aplicação dos Algoritmos Genéticos na maximização desse problema, estabeleceu-se que as variáveis x e y deveriam variar de 1 a 32, pois no domínio $[1, 32] \times [1, 32]$, como constatado, a função $R(x, y)$ passa por um máximo. Observe que poderia ser qualquer domínio que contivesse o ponto (20,16).

Utilizando-se uma precisão $\varepsilon = 0,03$, foi gerada uma população inicial composta de 20 números no intervalo de 1 a 1.024, correspondendo-se números na forma binária de 10 bits, de modo que, quando particionado ao meio, os dois números binários obtidos correspondem números decimais entre 1 e 32.

Na Tabela 3 está representada a primeira interação do algoritmo, composto de 2 números reais, de uma população inicial de 20 números reais, escolhidos aleatoriamente entre 1 e 1.024 e os seus correspondentes na base 2.

Particionando-se ao meio cada número binário obteve-se os correspondentes valores em binários, e reais, das variáveis x e y , os valores numéricos da função $R(x, y)$, as probabilidades P_i de passar à próxima geração e as probabilidades acumuladas Q_i de cada um dos valores de $R(x, y)$, para a implementação da roleta viciada.

Tabela 3. Dois elementos de uma população inicial de 20 elementos

n	Pop.Inicial (reais)	P.Inicial (binários)	x	y	x(real)	y(real)	R(x, y)	$R(x, y)^*$	Pi	Qi
1	295	0100100111	01001	00111	9	7	332.5	332.5	0.1789	0.1789
2	37	0000100101	00001	00101	1	5	82.5	82.5	0.0444	0.2232

Após doze iterações houve a convergência do algoritmo, obtendo-se a mesma solução já obtida anteriormente, isto é, $x = 20$, $y = 16$ e $F(16, 20) = 480$.

5 CONCLUSÕES

Os resultados podem ser considerados bons, visto que o objetivo deste trabalho foi alcançado, ou seja, com a utilização de Algoritmos Genéticos na solução de um problema de programação linear, no estudo de caso 1 pôde-se otimizar uma ração de frangos de corte, balanceando-a de acordo com os nutrientes necessários, de forma que os animais tenha o maior rendimento, e o criador tenha o menor custo com a mistura.

No estudo de caso 2, foi solucionado um problema de programação não-linear para o planejamento da produção diária de uma outra indústria que não tinha nenhuma restrição, nem de industrialização, nem de mercado. Neste caso, o problema também foi resolvido com a utilização do cálculo diferencial, pois neste caso a função era derivável, obtendo-se os mesmos resultados.

Esses dois problemas, também, foram resolvidos com a utilização da ferramenta *Solver* da MS_Excel 2003, com os mesmos resultados, o que não inviabiliza a aplicação de Algoritmos Genéticos nas suas soluções, já que esse último é indicado, também, na solução de problemas de otimização envolvendo funções não-lineares, deriváveis ou não no intervalo de soluções. Por outro lado, os algoritmos genéticos têm-se mostrado mais lentos que determinados métodos clássicos de otimização.

6 REFERÊNCIAS

ALENCAR, C. E. R. DE; CORRÊA, R. F. Ferramenta de suporte para a decisão de frentes de corte de cana-de-açúcar usando algoritmos genéticos. Trabalho de Conclusão de Curso. Recife: Escola Politécnica de Pernambuco, 2006.

BREGALDA, P. F.; OLIVEIRA, A. F. de; BORNSTEIN, C. T. **Introdução à Programação Linear**. Rio de Janeiro: Editora Campus Ltda., 1988.

CAIXETA FILHO, J. V.; GOLDBARG, M. C.; PACCA, H. L. L. **Otimização Combinatória e Programação Linear**: Modelos e Algoritmos. Rio de Janeiro: Editora Campus, 2000.

HILLIER, F. S.; LIEBERMAN, G. **Introdução à Pesquisa Operacional**. Rio de Janeiro: Editora Campus Ltda./Editora USP, 1988.

LINDEN, R. **Algoritmos genéticos**. Rio de Janeiro: Brasport, 2008.

LOESCH, C.; HEIN, N. **Pesquisa Operacional**: fundamentos e modelos. Blumenau: Editora da FURB, 1999.

MACULAN, N. F.; PEREIRA, M. V. F. **Programação Linear**. Rio de Janeiro: Editora Atlas, 1980.

MIRANDA, M. N. de. Algoritmos Genéticos: Fundamentos e Aplicações. Disponível em <http://www.gta.ufrj.br/~marcio/genetic.html>, 2009.

PACHECO, M. A. C. **Algoritmos genéticos**: princípios e aplicações. Disponível em <http://www.ica.ele.puc-rio.br/Downloads/38/CE-Apostila-Comp-Evol.pdf>. Acesso em 25/11/2009.

SANTA CATARINA, A.; BACH, S. L. Estudo do efeito dos parâmetros genéticos na solução otimizada e no tempo de convergência em algoritmos genéticos com codificações binária e real. **Acta Scientiarum**: Technology. Maringá, v. 25, n.2, p. 147- 152, 2003.

VIANA, G. V. R. **Meta-heurísticas e programação paralela em otimização combinatória**. Fortaleza: EUFC, 1998.

FERREIRA, R. S. **Matemática aplicada às ciências agrárias**: análise de dados e modelos. Viçosa : UFV, 1999.