

Uso de algoritmos genéticos como ferramenta auxiliar no processo decisório em atividades de gestão agroindustrial¹

Use of genetic algorithms as auxiliary tool for operational and economic decision making process of agro-industry activities

Celso Correia de Souza²
José Francisco dos Reis Neto³
Edison Rubens Arrabal Arias⁴
Wesley Osvaldo Pradella Rodrigues⁵

Resumo: A programação 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.

Abstract: Linear and nonlinear programming branches of applied mathematics have helped managers in business process management, allowing a decision to be simulated and analyzed extensively prior to its practical implementation. There are several applications in classic literature to solve such problems. More recently, genetic algorithms were available to provide efficient solutions for linear programming and nonlinear problems, which do not demand any requirement on the differentiability of functions involved. The research objective was to test the use of genetic algorithms to solve linear and nonlinear programming problems applied to agro-industry management. Two problem examples were solved. The first one was related to solution of integer linear programming problem and the second example dealt with a problem of nonlinear programming both applied in the agro-industry activities. The results can be considered good providing solutions identical to those obtained by using the well known Excel Solver, which has limitations on the number of variables and on functions continuity involved in nonlinear programming problems.

Keywords: Sugarcane crop; operational research; economical income.

JEL: M

¹ Artigo recebido em fevereiro de 2010 e aprovado em abril de 2010.

² Doutor em Engenharia Elétrica pela Universidade Estadual de Campinas. Professor Titular da Universidade para o Desenvolvimento do Estado e da Região do Pantanal. Campo Grande-MS, Brasil E-mail: ipc@uniderp.br

³ Mestre em Administração pela Universidade Federal do Rio Grande do Sul. Professor Titular da Universidade para o Desenvolvimento do Estado e da Região do Pantanal. Campo Grande-MS, E-mail: jfreisneto@terra.com.br

⁴ Doutor em Agronomia (Fitotecnia) pela Universidade Federal de Lavras. Professor titular da Universidade para o Desenvolvimento do Estado e da Região do Pantanal. Campo Grande-MS, E-mail: edisonarias@pop.com.br

⁵ Graduando do Curso de Administração da Universidade Anhanguera-Uniderp. Campo Grande-MS, E-mail: wesley174@uol.com.br

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.

A agroindústria canavieira, de grande importância atualmente no agronegócio brasileiro, é a mais antiga atividade econômica não-extrativista do Brasil, tendo o açúcar como o seu produto principal, desde o ano de 1540, data da implantação desta agroindústria no Brasil. Em meados de 1983, devido a grande alta do petróleo, o álcool carburante, (etanol), tomou o lugar do açúcar por pouco tempo, pois com a normalização dos preços do petróleo, houve uma grande demanda internacional pelo açúcar. Recentemente, contudo, seja em função do novo patamar dos preços do petróleo, seja em função, principalmente, do problema ambiental, surgiu a possibilidade de que o Brasil possa ser um grande exportador de etanol de cana-de-açúcar.

O planejamento da colheita de cana-de-açúcar visa otimizar o retorno agrônomo do empresário, visto que somente em uma época do ano, geralmente no período seco, a cana acumula o máximo de sacarose nos colmos. Após esse período, inicia-se o período de reprodução, em que é utilizado parte dos açúcares acumulados, diminuindo a produtividade.

Dentre os muitos aspectos gerenciais, a escolha do momento ideal para colheita de lotes da cana-de-açúcar é uma das decisões mais difíceis de tomar. Esta decisão deve levar em consideração um conjunto de critérios relacionados a esta prática agrônoma, como também outros aspectos industriais, com o intuito de reduzir custos operacionais e de demandas energéticas.

O planejamento agroindustrial é de importância fundamental para a obtenção de bons resultados econômicos, 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.

Assim sendo, o planejamento agroindustrial na colheita da cana-de-açúcar que visa a determinação da melhor época para a colheita de um determinado lote de cana, cujo acúmulo de açúcares no colmo seja o maior possível, é de grande importância para o empresário, pois propicia o maior lucro.

A utilização de modelos matemáticos e ferramentas computacionais na agroindústria da cana-de-açúcar vêm crescendo, impulsionada pelo planejamento agroindustrial que tem como objetivos obter melhor produtividade e rentabilidade. O setor agroindustrial canavieiro iniciou um processo de pesquisa e desenvolvimento que garante seu destaque no setor agrícola brasileiro.

As agroindústrias de cana-de-açúcar procuram se adequar ao cenário da economia nacional por meio de inovações como a melhor forma de integrar a área agrícola e a industrial. A necessidade da implantação de alternativas técnicas, equipamentos e recursos que beneficiem o planejamento e o controle do processo produtivo ocorrem em razão do aumento de competitividade no setor.

A programação linear e não-linear são modelos matemáticos, assistida por ferramentas computacionais, que auxiliam os empresários no planejamento

agroindustrial 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.

Uma aplicação importante da programação linear é a sua utilização pela agroindústria canavieira, como ferramenta para suporte à decisão da organização de frentes de corte de cana-de-açúcar em algumas regiões do Brasil, principalmente, no Nordeste e Sudeste.

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 possui pontos onde a mesma 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. 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.

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

2 Referencial teórico

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).

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

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); $b_i \in \mathfrak{R}$, ($i = 1, 2, \dots, m$), níveis de disponibilidade de recursos ou quantidade mínima a ser suprida. *Otimizar* engloba os problemas de maximização ou 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® que, certamente, é o de mais fácil acesso devido a popularidade desta planilha eletrônica, possibilitando acesso à maioria dos leitores que usam microcomputadores (CAIXETA e FILHO et al., 2000).

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; ALCALÁ et al, 2003).

2.1.1 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.

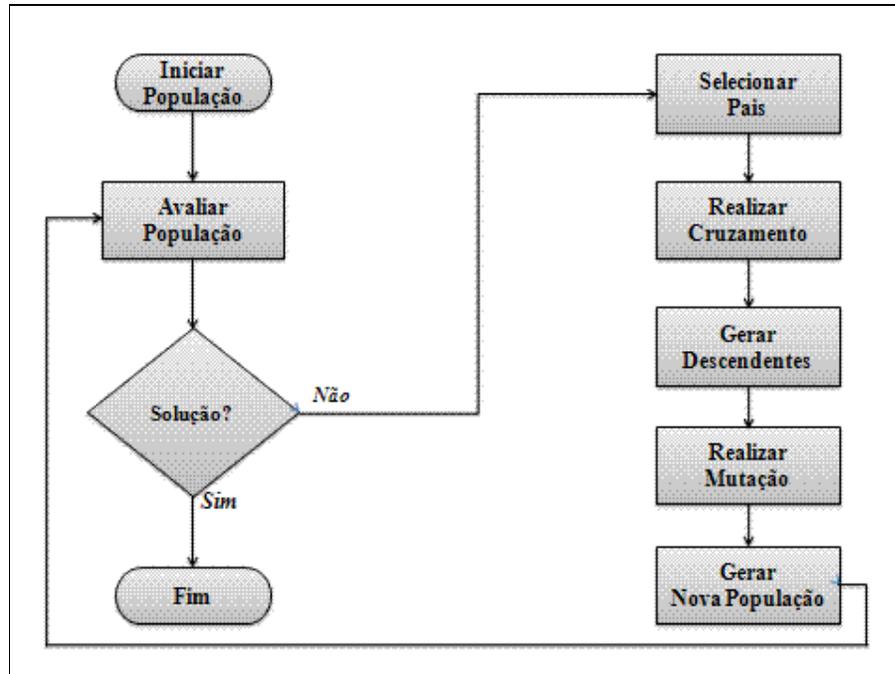
O algoritmo genético básico é o que realiza as seguintes funções: inicializa a população de cromossomos; avalia cada cromossomo da população; cria novos cromossomos a partir da população atual (realiza cruzamento e mutação); e termina, se o critério de fim for alcançado, se não, reinicializa.

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 (BITTENCOURT, 1998; HOLLAND, 1975; SANTA CATARINA & BACH, 2003).

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 (KARR, 1993). Na Figura 1 é possível resumir os Algoritmos Genéticos através do fluxograma.

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



Fonte: Alencar & Corrêa (2006); Guervós (2009); Linden (2008); Viana (1998); Pacheco (2009); Langdon & Polli (2002); Karr, (1993)

A aplicação dos Algoritmos Genéticos, como descrito pelo fluxograma da Figura 1, consta dos seguintes passos:

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;

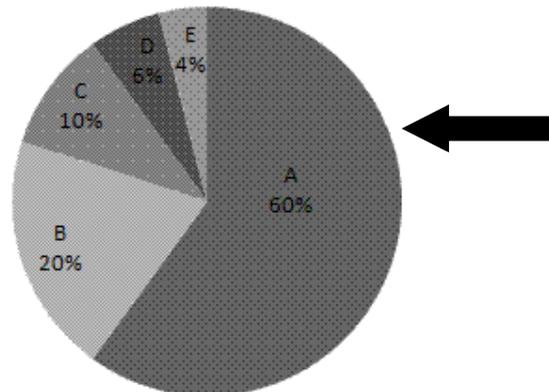
Seleção Via Método da Roleta Viciada - este método emprega o princípio da probabilidade de sobrevivência do mais apto, ou seja, que possui a melhor função objetiva associada. Com base nos valores de $f_i(x_i)$, onde x_i é o indivíduo i avaliado entre os n indivíduos amostrados.

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 (ALCALÁ et. al., 2003).

Figura 2 - Seleção de indivíduos através da roleta viciada



Fonte: Resultados da Pesquisa

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 (MITCHELL, 1998).

Quando a evolução está avançada, em que as aptidões não diferenciam entre si, pode causar uma 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. Recomenda-se que a taxa de cruzamento deve em geral ser alta, cerca de 80% à 95%. Entretanto, alguns resultados mostram que para alguns tipos de problemas, uma taxa de cruzamento de cerca de 60% é o melhor.

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 (Cartwright, 2006).

. 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 uma agroindústria que dispõe de 15 lotes de cana-de-açúcar, de diferentes áreas, a serem colhidos, dando preferência aqueles que têm os maiores teores de sacarose, visando o maior rendimento em açúcar bem como a maior quantidade de fibras para a co-geração de energia elétrica com a queima do bagaço, além de respeitar a capacidade de moagem da indústria.

A função objetiva (05) a ser maximizada deve priorizar os valores de sacarose, denotado por PCC (Porcentagem de Sacarose no Caldo de Cana) e Fibra, representadas por $f(x)$ e $g(x)$, respectivamente. Assim, a função $f(x)$ está ligada ao rendimento de açúcar no colmo e $g(x)$ ao bagaço da cana que será queimado nas caldeiras visando a co-geração de energia elétrica.

$$z = f(x) + g(x) \quad (05)$$

As funções $f(x)$ e $g(x)$ foram normalizadas para que pudessem ser somadas, ou seja:

$$f(x) = \frac{100 \times \sum_{i=1}^N x_i \times \text{PCC}_i}{\sum_{i=1}^N \text{PCC}_i} \quad \text{e} \quad g(x) = \frac{100 \times \sum_{i=1}^N x_i \times \text{Fibra}_i}{\sum_{i=1}^N \text{Fibra}_i}$$

As incógnitas x_i ($i=1,2,\dots,N$) indicam os lotes de cana-de-açúcar a serem colhidos. As funções $f(x)$ e $g(x)$ podem ser multiplicadas por α ($0 \leq \alpha \leq 1$) e $(1-\alpha)$, respectivamente, obedecendo a um critério de ponderação, que é fornecido pelo usuário

para determinar o grau de relevância de cada uma das funções (Alencar, 2006). A função z , expressão (05), está sujeita a uma restrição TESP (Tonelagem Esperada), expressão (06), que deve ser menor ou igual à capacidade de moagem de cana da agroindústria $TDES$ (Tonelagem Desejada).

$$TESP = \sum_{i=1}^N x_i \times Area \times TCH_i \quad (06)$$

Por conveniência, não foi permitido a colheita de uma fração de um lote, se tratando, então, de um problema de programação linear inteira, expressão (07).

$$\begin{aligned} \text{Máx } z &= f(x) + g(x) \\ s / a &\begin{cases} TESP \leq TDES \\ x_i \geq 0 \\ x_i \text{ int eiro} \end{cases} \end{aligned} \quad (07)$$

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).

$$\text{Máx } z = R(x, y) \quad (08)$$

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 de uma agroindústria que pretende colher os lotes de cana-de-açúcar que têm os maiores teores de sacarose visando o maior rendimento em açúcar, bem como a maior quantidade de fibras para a co-geração de energia elétrica com a queima do bagaço, além de respeitar a capacidade de moagem da indústria.

A entrada de dados foi através de uma planilha Excel com os dados dos 15 lotes de cana-de-açúcar (Tabela 1).

Tabela 1 - Dados econômicos de lotes de cana-de-açúcar de uma agroindústria de açúcar e álcool do Noroeste do Estado de São Paulo, Brasil, em 2005

Lote (nº.)	Área (ha)	PCC (%)	TCH (t)	Fibra (t)
1	35	1265.035	1133.728	1252.870
2	33	1260.168	9348.303	1628.966
3	34	1530.017	8564.792	1556.353
4	24	1403.548	5886.500	1831.322
5	44	1435.194	8842.609	1577.891
6	15	1284.694	8716.410	1525.948
7	34	1359.935	8798.350	1549.224
8	43	1359.610	7198.433	1729.352
9	17	1273.662	9225.992	1466.953
10	12	1444.317	9171.265	1436.881
11	34	1532.613	7416.440	1560.824
12	34	1516.294	8298.039	1388.719
13	30	1259.958	9890.481	1561.156
14	14	1396.753	6684.964	1769.721
15	19	1513.373	9335.743	1541.483

Fonte: (ALENCAR, 2006).

Obtido o sistema (07) a partir dos dados da Tabela 1, o problema de programação linear inteira foi resolvido aplicando-se Algoritmos Genéticos, simulando três níveis de capacidade de moagem TDES (Tonelagem Desejada), ligadas à capacidade da agroindústria.

Inicialmente, foram gerados 30 números aleatórios no sistema binário, população inicial, cada um com 15 bits, cada bit representando um lote, de acordo com a sua posição no número, dos 15 lotes de cana a serem colhidos. O bit 0 significava que o lote não seria colhido, enquanto o bit 1 indicava que aquele lote seria cortado.

Para cada número binário gerado, eram somadas as toneladas de cana a serem cortadas, dos lotes correspondentes aos bits 1, para a verificação do atendimento à tonelagem desejada, que correspondia à capacidade da agroindústria. Caso um indivíduo não atendesse, era descartado e gerado outro em seu lugar.

Sobre essa população inicial, e nas demais, foram aplicadas todas as etapas de cada iteração dos Algoritmos Genéticos: avaliação, seleção, cruzamento e mutação, com a finalidade de melhorar as novas populações. Na Tabela 2 estão os valores ótimos para os três níveis de capacidade de moagem TDES, as toneladas esperadas TESP, os lotes colhidos e os números binários finais, lembrando que a posição do dígito zero significa que aquele lote não foi colhido, enquanto a posição do dígito um significa que o lote foi colhido.

Tabela 2 - Resultados de três simulações sobre a determinação de lotes de cana-de-açúcar a serem colhidos visando o maior retorno econômico

Simulação	TDES (t)	TESP (t)	Lotes colhidos	Binário final
1	2000	1924.94	13, 14	000101000100010
2	4800	4756.67	4, 6, 10, 14	000101000100010
3	9000	8846.68	4, 6, 9, 10, 11, 14	000101001110010

Fonte: Resultados da Pesquisa.

As Percentagens totais de açúcar no Caldo de Cana e a Fibra total podem ser calculadas a partir dos dados das Tabelas 1 e 2.

Esse sistema também foi resolvido com a utilização da ferramenta Solver do Excel, para os três níveis de capacidade de moagem TDES, 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 tratou-se de um problema idealizado de uma agroindústria que produz dois tipos de produtos A e B que, colocados no mercado, origina uma receita representada pela função não-linear $R(x, y)$ nas variáveis x e y , numa unidade monetária qualquer, com x representando o número de unidades produzida do produto A e y o número de unidades produzida do produto B. A agroindústria tem como meta maximizar essa receita estabelecendo os níveis ideais de produção dos produtos A e B visando essa meta.

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

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

Resolvido o problema de máximo utilizando-se o método clássico, com a utilização do Cálculo Diferencial, pois $R(x, y)$ é derivável nas variáveis x e y em todo o seu domínio de definição, encontrou-se $R_{\max}(20,16) = 480$. Assim, devem ser produzidas 20 unidades do produto A e 16 unidades do produto B, auferindo-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). Existem métodos clássicos para a determinação de intervalos que contém raízes de funções.

Utilizando-se uma precisão $\varepsilon = 0,03$, foi gerada uma população inicial composta de 20 números ($n = 20$), 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 iteração do algoritmo, composto de 2 números reais, de uma população inicial (Pop.Inicial), de 20 números reais, escolhidos aleatoriamente entre 1 e 1.024 e os seus correspondentes na base 2, o particionamento ao meio de cada binário, gerando os binários x_i e y_i , os correspondentes valores em reais dessas duas variáveis $x_i(\text{real})$ e $y_i(\text{real})$, os valores numéricos da função $R_i(x, y)$, as probabilidades P_i de passar à próxima geração e as probabilidades acumuladas Q_i de cada um dos valores de $R_i(x, y)$, $i = 1, 2, 3, \dots, n$, para a implementação da roleta viciada.

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

I	Pop.Inicial (reais)	Pop.Inicial (binários)	x_i	y_i	$x_i(\text{real})$	$y_i(\text{real})$	$R_i(x, y)$	P_i	Q_i
1	295	0100100111	01001	00111	9	7	332.5	0.1789	0.1789
2	37	0000100101	00001	00101	1	5	82.5	0.0444	0.2232

Fonte: Resultados da Pesquisa.

Após doze iterações dos Algoritmos Genéticos, implementados no MS Excel, houve a convergência do algoritmo, obtendo-se a mesma solução já obtida anteriormente através do método clássico, isto é, $x = 20$, $y = 20$ e $F(16, 20) = 480$.

Conclusão

Os resultados podem ser considerados bons, visto que o objetivo deste trabalho foi alcançado, ou seja, com a utilização de Algoritmos Genéticos, no estudo de caso 1, na tomada de decisão no planejamento de uma agroindústria visando o maior retorno econômico e atendendo determinadas limitações dessa atividade. Com isso, pôde-se planejar a produção diária de uma indústria que dispunha de insumos em quantidades limitadas para a fabricação de açúcar e visando o maior rendimento econômico, ao mesmo tempo em que a fibra era usada para a co-geração de energia elétrica, respeitadas todas as restrições impostas à indústria em termos de capacidade de moagem da agroindústria..

No estudo de caso 2, foi solucionado um problema de programação não-linear para o planejamento da produção diária de outra agroindústria 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.

Nos dois casos as soluções via Algoritmos Genéticos foram implementadas no aplicativo MS Excel, utilizando-se planilhas de cálculos, o que tornou os processamentos custosos e demorados. Se a opção fosse a programação desse algoritmo em qualquer linguagem computacional, como C++, Delphi, entre outros, o processo seria muito mais rápido.

Esses dois problemas também foram resolvidos com a utilização da ferramenta Solver da MS_Excel, 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.

A utilização de Algoritmos Genéticos como ferramenta auxiliar no processo decisório tem muito mais vantagens do que desvantagens. Pode-se enumerar algumas vantagens: é uma técnica de fácil implementação, não exigindo aprofundados conhecimentos matemáticos; utilizam informação de custo e benefício; não é necessária informação acerca do gradiente da função objetivo, portanto não está atrelado à derivada da função; descontinuidades ou complexidades existentes na representação gráfica do problema não apresentam influência significativa; trabalham com toda a população e não com um único ponto o que permite realizar buscas simultâneas em vários espaços de busca; a presença de mínimos locais não reduz a eficiência do algoritmo; o desempenho do algoritmo tem apresentado bons

resultados em problemas de otimização de grande porte; pode ser utilizado com outras heurísticas e; utilizam regras de transição probabilísticas e não determinísticas.

Pode-se, também, enumerar algumas desvantagens: dificuldade em se encontrar o valor ótimo exato; é necessário efetuar muitas avaliações de valores de Aptidão e; existem muitas possibilidades de configurações dos genes.

As aplicações dos algoritmos genéticos são vastas, podendo-se destacar: problemas de otimização, objetivo desse trabalho; o problema do caixeiro viajante; problemas de sequenciamento; escalonamento de pessoal; síntese de circuitos analógicos; evolução musical; obtenção de retratos falados, entre outros.

Referências

ALCALÁ, R, BENITEZ, J. M.,CASILLAS, J., CORDÓN, O., PÉREZ, R., Fuzzy Control of HVAC Systems Optimized by Genetic Algorithms. Applied Intelligence, v.18 n.2, p.155-177, March-April 2003

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 E BORNSTEIN, C. T., Introdução à Programação Linear. Rio de Janeiro: Editora Campus Ltda., 1988.

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

CARTWRIGHT, H. M. The Genetic Algorithm in Science. Physical and Theoretical Chemistry Laboratory. Oxford University, UK, 1996. Disponível em (<http://www.citesser.ist.psu.edu/79259.html>). Acessado em 28 de abril de 2010.

GUERVÓS, J. J. M. Informática Evolutiva: Algoritmos Genéticos. Disponível em <http://geneura.urg.es/~jmerelo/ie/ags.htm>. Acessado em 22/11/2009.

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

KARR, C. L., Genetic algorithms for modelling, design, and process control. Proceedings of the second international conference on Information and knowledge management, p.233-238. November 01-05, 1993. Washington, D.C., United States.

LANGDON, W. e POLI, R., Foundations of Genetic Programming. Springer Verlag Pub, 2002.

LINDEN, R., Algoritmos Genéticos. Rio de Janeiro: Brasport, 2008.

MACULAN N. F. e PERREIRA, 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>. Acessado em 28 de abril de 2009.

MITCHELL, M., An Introduction to Genetic Algorithms. The Mit Press, 1998.

MIYAZAWA, F. K. Otimização Combinatória. Disponível em <http://www.ic.unicamp.br/~fkm/problems/combopt.html>. Acessado em 28 de abril de 2010.

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>. Acessado em 28 de abril de 2010.

SANTA CATARINA, A. e 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.