

Utilização de um algoritmo genético na otimização do lucro de uma propriedade agrícola

Adair Santa Catarina^{1*}, Miguel Angel Uribe Opazo² e Sirlei Lourdes Bach³

¹Curso de Informática, Universidade do Oeste do Paraná, Rua Universitária, 2069, 85814-110, Cascavel, Paraná, Brasil. ²Curso de Matemática, Unioeste, Rua Universitária, 2069, 85814-110, Cascavel, Paraná, Brasil. ³Curso em Tecnologia em Processamento de Dados, Univel, Av. Tito Muffato, 2317, 85806-080, Cascavel, Paraná, Brasil. *Autor para correspondência. E-mail: asc@unioeste.br

RESUMO. Este artigo apresenta um Algoritmo Genético (AG) utilizado para otimizar o lucro de uma propriedade agrícola. Um protótipo de software chamado “AG Optimizer” foi desenvolvido para aplicar um AG nesta otimização. Compararam-se os resultados da otimização realizada pelo AG com os resultados obtidos através de um método determinístico, o método Simplex. O método Simplex forneceu um lucro de R\$ 34.639,85 enquanto que o AG forneceu um lucro variando entre R\$ 32.756,91 e R\$ 34.387,08. Estes valores confirmam que AGs podem ser utilizados para otimizar o lucro de uma propriedade agrícola.

Palavras-chave: algoritmos genéticos, otimização, programação linear.

ABSTRACT. Farm profit optimization using a genetic algorithm. This paper presents a Genetic Algorithm used to optimize the profit of an agricultural farm. A software prototype called “AG Optimizer” was created to apply a Genetic Algorithm in this optimization. A comparison between the optimization results using a Genetic Algorithm and deterministic method was made. The profit calculated through deterministic method, Simplex Method, was R\$ 34,639.85 whereas the Genetic Algorithm provided a profit varying between R\$ 32,756.91 and R\$ 34,387.08. These values confirm that Genetic Algorithms can be used to optimize the profit in agricultural farms.

Key words: genetic algorithms, optimization, linear programming.

Introdução

Este trabalho apresenta um método alternativo para resolução dos Problemas de Programação Linear (PPLs), geralmente resolvidos através do Método Simplex. O método proposto como alternativa é um Algoritmo Genético (AG). AGs são algoritmos de busca baseados em mecanismos de seleção natural.

Desenvolveu-se um modelo de Programação Linear para maximizar o lucro obtido numa propriedade agrícola do Município de Maripá, Estado do Paraná. Para resolver o problema proposto, utilizando um AG, implementou-se um protótipo de software: o “AG Optimizer”.

O AG proposto aplica-se exclusivamente ao modelo de Programação Linear aqui desenvolvido. Entretanto, pode-se adaptá-lo para outros modelos de Programação Linear, bem como modelos de Programação Não-linear.

Otimização do lucro de propriedades agrícolas

Nas últimas 4 décadas, observou-se o êxodo rural. O censo demográfico de 1960 constatou que a população rural representava 55,3% da população brasileira; já na década de 1980, este percentual diminuiu para 32,4% e, no último censo demográfico, em 2000, era de apenas 18,7% (IBGE, 1996, 2002).

Um dos fatores que levou os agricultores a abandonar o campo é a baixa renda obtida na propriedade agrícola. O planejamento e controle das atividades agrícolas contribuem para elevar esta renda. Segundo Oliveira (1995), o planejamento agrícola é o principal instrumento para que o produtor rural atinja os objetivos por ele estabelecidos.

Fileto (1997) afirmou que é preciso acompanhar o processo de produção. Assim, seria possível apurar os custos e o rendimento obtido a cada ciclo de cada cultura, identificando os pontos falhos e corrigindo-

os de maneira a maximizar o uso do potencial produtivo da propriedade agrícola.

Martin (1994) citou que, à medida que a agricultura vem se tornando cada vez mais competitiva, o custo de produção constitui informação importante no processo de decisão e que estimar este custo ficou mais simples à medida que se aumentou a adoção da informática na gestão das empresas agropecuárias.

Outra forma de se aumentar a renda do homem do campo é a otimização do sistema propriedade agrícola. Vários autores propuseram alternativas neste sentido.

Salokhe e Pariyar (1990) apresentaram um estudo para otimização de propriedades agrícolas na região do Tarai, no Nepal, objetivando aumentar o lucro em propriedades de 1,5 e 5 ha.

Oliveira (1995) criou um sistema informatizado com o objetivo de auxiliar administradores de empresas rurais na fase de planejamento das atividades agrícolas. Este sistema buscava maximizar o lucro das atividades aptas ao cultivo durante o ano agrícola.

Rodrigues (1997) apresentou um modelo para o planejamento estratégico de uma propriedade de leite objetivando a otimização global do sistema, maximizando sua lucratividade.

Fato comum às propostas supracitadas foi a criação de modelos de Programação Linear. Nesses modelos, todas as funções envolvidas são lineares e o número de variáveis envolvidas é elevado, fazendo com que sua manipulação exija, por vezes, o uso de sistemas computadorizados.

“A Programação Linear é um meio matemático de designar um montante fixo de recursos que satisfaça certa demanda de tal modo que alguma função-objetivo seja otimizada e ainda se satisfaça a outras condições definidas”. (Shamblin e Stevens, 1979, p.263).

“A Programação Linear é um procedimento matemático para designar ou distribuir uma quantidade fixa de recursos para uma determinada finalidade, de tal modo que alguma função ou objetivo seja otimizado.” (Shimizu, 1984, p.124).

Goldbarg e Luna (2000, p.31-32) apresentaram as características para que um sistema possa ser representado por meio de um modelo de Programação Linear:

- Proporcionalidade: a quantidade de recurso consumido por uma dada atividade deve ser proporcional ao nível dessa atividade na solução final do problema. Além disso, o custo de cada atividade é proporcional ao nível de operação da atividade;

- Não Negatividade: deve ser sempre possível desenvolver dada atividade em qualquer nível não negativo e qualquer proporção de um dado recurso deve sempre poder ser utilizado;
- Aditividade: o custo total é a soma das parcelas associadas a cada atividade;
- Separabilidade: pode-se identificar de forma separada o custo, ou consumo de recursos, específico das operações de cada atividade.

Algoritmos genéticos

Os Algoritmos Genéticos são um tipo de algoritmo de busca que se utilizam do paradigma genético/evolucionário (Holland, 1975). AGs foram criados com o intuito de imitar alguns dos processos observados na evolução natural das espécies.

Segundo Bittencourt (1998), os AGs são o ramo mais conhecido da Computação Evolutiva e tiveram origem no trabalho de Holland, nos anos da década de 1960.

No começo dos anos 70, John Holland, quando pesquisava as características da evolução natural, acreditou que, se estas características fossem adequadamente incorporadas a algoritmos computacionais, poderia produzir uma técnica para solucionar problemas difíceis da mesma forma que a natureza fazia para resolver os seus problemas, ou seja, usando a evolução.

Acreditando nisto, ele deu início a uma pesquisa sobre algoritmos que manipulavam “strings” de 0's (zeros) e 1's (uns), a qual ele deu o nome de cromossomos. Os algoritmos de Holland realizavam a evolução simulada de populações destes cromossomos. Desta forma, imitando a natureza, seus algoritmos resolviam muito bem o problema de encontrar bons cromossomos através da manipulação do material contido nos cromossomos.

Outro ponto interessante nas técnicas desenvolvidas por Holland é que, assim como na natureza, estes cromossomos não têm conhecimento nenhum sobre o tipo de problema que estão resolvendo. A única informação que eles dispunham era uma avaliação de cada cromossomo produzido. O objetivo desta avaliação era verificar quais os cromossomos que estavam mais adaptados e, com base nisto, aumentar as suas chances de serem selecionados para a reprodução.

O elemento de ligação entre o AG e o problema a ser resolvido é a função de avaliação. A função de avaliação, chamada de função “fitness”, toma como entrada um cromossomo e retorna um número ou lista de números que representam a medida de performance do cromossomo, com relação ao problema a ser resolvido. Esta função desempenha

no AG o mesmo papel desempenhado pelo meio ambiente na teoria da evolução natural das espécies.

Em 1983, Goldberg conseguiu o primeiro sucesso em aplicação industrial de AGs, resolvendo um problema de otimização que envolvia um sistema de bombeamento de combustível.

Segundo Goldbarg e Luna (2000), os AGs possuem as seguintes características gerais:

- Operam em um conjunto de pontos, denominados população, e não a partir de pontos isolados;
- Operam em um espaço de busca de soluções codificadas e não diretamente no espaço de busca;
- Necessitam, como informação de avaliação, somente o valor de uma função objetivo, denominada função de adaptabilidade ou “fitness”;
- Usam transições probabilísticas e não regras determinísticas.

Os operadores de seleção, cruzamento e mutação estão intimamente relacionados no modelo básico de um algoritmo genético, e os três fazem a evolução da população acontecer. A finalidade da seleção em um algoritmo é escolher os elementos da população que devem se reproduzir, de tal forma que dê maior chance de reprodução aos membros da população mais adaptados ao meio ambiente, isto é, àqueles que apresentam melhor “fitness”. A mais conhecida e utilizada forma de se fazer a seleção é a roleta, ou algoritmo Monte Carlo (Davis, 1996; Mendes F², 1998).

O Elitismo é o método mais utilizado para melhorar a convergência dos AGs e é uma adição aos métodos de seleção que força os AGs a reter um certo número de “melhores” indivíduos em cada geração (Yepes, 2000). Tais indivíduos podem ser perdidos se eles não forem selecionados para reprodução ou se eles forem destruídos por cruzamento ou mutação.

O objetivo final dos operadores cruzamento e mutação é fazer com que os cromossomos criados durante o processo de reprodução sejam diferentes dos cromossomos dos pais. O operador de cruzamento é responsável por combinar os cromossomos dos pais na criação dos cromossomos filhos, e o operador de mutação é responsável pela introdução de pequenas mudanças aleatórias nos cromossomos dos filhos.

Alguns parâmetros influem no comportamento dos Algoritmos Genéticos, sendo estabelecidos conforme as necessidades do problema e dos recursos disponíveis.

- Tamanho da População: determina o número de cromossomos na população, afetando o desempenho global e a eficiência dos AGs. Com uma população pequena o desempenho pode cair, pois deste modo a população fornece uma pequena cobertura do espaço de busca do problema. Uma grande população geralmente fornece uma cobertura representativa do domínio do problema, além de prevenir convergências prematuras para soluções locais ao invés de globais. No entanto, para se trabalhar com grandes populações, são necessários maiores recursos computacionais, ou que o algoritmo trabalhe por um período de tempo muito maior.
- Taxa de Cruzamento: determina a probabilidade em que um cruzamento ocorrerá. Quanto maior for esta taxa, mais rapidamente novas estruturas serão introduzidas na população. Mas se esta for muito alta, a maior parte da população será substituída, e pode ocorrer perda de estruturas de alta aptidão. Com um valor baixo, o algoritmo pode tornar-se muito lento.
- Taxa de Mutação: determina a probabilidade em que uma mutação ocorrerá. Uma baixa taxa de mutação previne que uma dada posição fique estagnada em um valor, causando uma convergência prematura, além de possibilitar que se chegue em qualquer ponto do espaço de busca. Com uma taxa muito alta a busca se torna essencialmente aleatória.

Os parâmetros genéticos acima citados afetam diretamente o desempenho dos AGs. Os efeitos decorrentes da escolha inadequada destes parâmetros vão desde aumento no tempo de convergência, convergência prematura, estagnação da busca, maior necessidade de recursos computacionais até a não-convergência para uma solução viável.

Funções de penalização

Na resolução de Problemas de Otimização Combinatória (POCs), sujeitos a restrições, os AGs devem avaliar se um indivíduo da população pertence ao espaço de busca. No caso afirmativo, seu “fitness” é calculado e, sendo um bom indivíduo, estará apto a participar do processo evolutivo. No caso negativo, o indivíduo viola uma ou mais restrições, deixando de representar uma solução viável e, portanto, não tem seu “fitness” avaliado.

Goldberg (1989) afirma que este seria um bom procedimento, mas muitos problemas práticos são

altamente restritos e encontrar uma solução viável é quase tão difícil quanto encontrar a melhor solução.

Segundo Cortes (1996), os fundamentos da teoria que originou os AGs afirmam que a otimização é alcançada pela combinação de informações parciais de toda a população. Ou seja, as soluções que não atendem às restrições podem conter informações importantes e que não devem ser desprezadas.

Goldberg (1989) propõe diminuir o “fitness” destas soluções inviáveis relacionando-as com o grau de violação das restrições através de uma função de penalização.

Segundo Goldberg (1989) e Joines e Houck (1994), as funções de penalização transformam um POC com restrições num POC sem restrições, através da penalização das soluções que são inviáveis.

Para Joines e Houck (1994), a principal limitação das funções de penalização é a definição do grau em que cada restrição será penalizada. Diversos pesquisadores têm declarado que há maior ênfase na busca por soluções viáveis quando se adota um alto grau de penalização; assim, os AGs movem-se mais rapidamente para soluções viáveis.

Um exemplo de aplicação de função de penalização relacionada ao número de restrições violadas é apresentado a seguir.

$$\begin{aligned} &\text{Minimizar } g(\bar{X}) \\ &\text{Sujeito a: } h_i(\bar{X}) \geq 0 \text{ com } i = 1, 2, \dots, n \end{aligned} \quad (1)$$

Removem-se as restrições deste problema, pela adição de uma função de penalização, da seguinte forma:

$$\text{Minimizar } g(\bar{X}) + r \cdot \sum_{i=1}^n \Phi[h_i(\bar{X})] \quad (2)$$

onde:

\bar{X} : vetor que representa o conjunto das variáveis envolvidas no problema;

Φ : função de penalização;

r: coeficiente de penalização.

Segundo Goldberg (1989), sob certas condições, a solução sem restrições converge para a solução com restrições, quando o coeficiente de penalização tende ao infinito.

Cortes (1996) afirmou que penalizações em função da distância da região viável apresentam melhor desempenho do que aquelas que são meramente relacionadas ao número de restrições violadas.

Joines e Houck (1994) propuseram o uso de uma função de penalização não estacionária para resolver problemas de otimização não-lineares restritos com AGs. Neste método, um incremento gradativo na penalização é aplicado através do aumento do fator penalidade, proporcionado pelo número da geração. O método é descrito a seguir:

$$\begin{aligned} &\text{minimizar } f(\bar{X}) \\ &\text{sujeito a: } \begin{cases} g_i(\bar{X}) \geq 0, & i = 1, \dots, m \\ h_j(\bar{X}) = 0, & j = 1, \dots, p \end{cases} \end{aligned} \quad (3)$$

onde:

f: função objetivo;

$g_i(\bar{X})$: restrições do tipo inequação;

$h_j(\bar{X})$: restrições do tipo equação;

m: número de restrições do tipo inequação;

p: número de restrições do tipo equação.

Adotando uma função de penalização tem-se:

$$\text{minimizar } F(\bar{X}, \rho_k) = f(\bar{X}) + P(\rho_k, \bar{X}) \quad (4)$$

$$\rho_k = c \cdot k \quad (5)$$

$$D_i(\bar{X}) = \begin{cases} 0, & \text{se } g_i(\bar{X}) \geq -\varepsilon \\ |g_i(\bar{X})|, & \text{nos outros casos} \end{cases} \quad 1 \leq i \leq m$$

$$D_j(\bar{X}) = \begin{cases} 0, & \text{se } -\varepsilon \leq h_j(\bar{X}) \leq \varepsilon \\ |h_j(\bar{X})|, & \text{nos outros casos} \end{cases} \quad 1 \leq j \leq p \quad (6)$$

$$SVC(\beta, \bar{X}) = \sum_{i=1}^m D_i^\beta(\bar{X}) + \sum_{j=1}^p D_j^\beta(\bar{X}) \quad (7)$$

$$P(\alpha, \beta) = \rho_k^\alpha \cdot SVC(\beta, \bar{X})$$

onde:

ρ_k : fator penalidade;

c, α e β : constantes;

k: número da geração;

ε : erro máximo permitido;

SVC: soma das restrições violadas;

β : função de penalização.

Material e métodos

Modelagem do problema de otimização

Modelou-se um PPL para uma propriedade rural do Município de Maripá, Estado do Paraná,

objetivando-se maximizar seu lucro (Fey *et al.*, 2000).

A propriedade possui 43 ha de área agricultável e nela são cultivadas as seguintes culturas: soja precoce, soja, milho, feijão das águas, milho safrinha, trigo, feijão das secas, mandioca e aveia. Estas culturas, implementadas na safra de verão 98/99 e inverno 99, proporcionaram um lucro total de R\$ 31.377,64 no período.

A função objetivo foi escrita com base nos lucros apresentados pelas culturas cultivadas na propriedade:

$$\begin{aligned} \text{Maximizar} \\ Z = & 816,33\text{ASN} + 428,97\text{ASP} + 245,63\text{AMN} + 136,63 \\ & \text{AMS} - 151\text{AFA} - 366,34\text{AFS} + 1223,06\text{AMA} - \\ & 140\text{AAV} + 189,46\text{ATR} \end{aligned} \quad (9)$$

em que:

Z = Função objetivo = Lucro [R\$];
 ASN = Área de soja [ha];
 ASP = Área de soja precoce [ha];
 AMN = Área de milho [ha];
 AMS = Área de milho safrinha [ha];
 AFA = Área de feijão das águas [ha];
 AFS = Área de feijão das secas [ha];
 AMA = Área de mandioca [ha];
 AAV = Área de aveia [ha];
 ATR = Área de trigo [ha].

Modelaram-se 36 restrições: 5 restrições de terras, 7 restrições de rotação de culturas, 3 restrições financeiras e 21 restrições de maquinaria agrícola. As restrições, bem como sua interpretação, podem ser obtidas em Fey *et al.* (2000).

Estruturação dos parâmetros para resolução dos problemas através de AGs

Nesta seção, definiram-se os parâmetros necessários para a aplicação de AGs na resolução do PPL proposto.

O cromossomo deverá representar a área que é possível atribuir a uma cultura específica. São 9 culturas diferentes na propriedade; portanto, formou-se um cromossomo com 9 genes. Cada um dos genes será constituído por uma seqüência de 0s e 1s, os quais representarão em forma binária, um valor decimal compreendido entre 0 e 43. Este valor decimal corresponderá à área de terra destinada à cultura correspondente àquele gene. O limite mínimo de área a ser atribuída a uma cultura é 0 ha; o limite máximo é 43 ha, a área total da propriedade.

A Figura 1 mostra a representação de um gene que representa uma área de 13,5 ha atribuída a uma

cultura qualquer. Os 6 alelos, mais à esquerda, representam a parte inteira do número, enquanto que os 4 alelos, mais à direita, representam a parte fracionária. Esta representação proporciona um erro menor ou igual a $6,25 \cdot 10^{-2}$ ha.

0 0 1 1 0 1 1 0 0 0

Figura 1. Um gene representando uma área de 13,5 ha

O cromossomo deverá representar um conjunto com as áreas atribuídas as 9 diferentes culturas que são conduzidas na propriedade. Portanto, o cromossomo foi constituído por 9 genes. A Figura 2 mostra um cromossomo que representa um possível vetor solução para o modelo proposto.

| | |
|-------------------------|------------|
| 00110111000110001010... | 0001010101 |
| Gene 1 | Gene 9 |

Figura 2. Um cromossomo representando um possível vetor solução

A influência dos parâmetros genéticos no desempenho do algoritmo depende da classe de problemas que se está tratando. Assim, a determinação de um conjunto de valores otimizado para estes parâmetros dependerá da realização de vários testes.

Testes iniciais mostraram que o AG implementado convergia adotando população inicial de, no mínimo, 20 indivíduos. Fixou-se, em 512 indivíduos, o tamanho máximo da população, pois valores maiores que esse tornaram o AG lento e não produziram melhores resultados.

Da mesma forma, taxas de cruzamento escolhidas entre 70 e 90% e taxas de mutação escolhidas entre 0,5 e 2%, mostraram-se adequadas para o problema em estudo. Além disso, estes valores estão em consonância com aqueles divulgados na literatura da área.

A avaliação ("Fitness") verifica se o cromossomo representa uma boa solução. A função de avaliação é a função objetivo representada pela equação 9. Utilizaram-se as 36 restrições do modelo para verificar se a solução proposta está contida no espaço de busca.

Para realizar a seleção implementou-se o método com função de penalização não-estacionária proposto por Joines e Houck (1994), adotando-se os valores sugeridos pelos autores para as constantes: $c = 0,5$, $\alpha = 1$ e $\beta = 2$.

O protótipo "AG Optimizer"

O volume de informações processadas através dos AGs é elevado, sendo inviável o processo

manual. Assim, desenvolveu-se um protótipo de software para a resolução do problema de otimização do lucro de uma propriedade agrícola utilizando-se de AGs.

Este protótipo foi desenvolvido em linguagem visual, Borland Delphi 3, compatível com o sistema operacional Microsoft® Windows.

A interface do protótipo desenvolvido é apresentada na Figura 3. Na Figura 4 é apresentado o fluxograma básico do protótipo “AG Optimizer”.



Figura 3. Interface do protótipo de software “AG Optimizer”

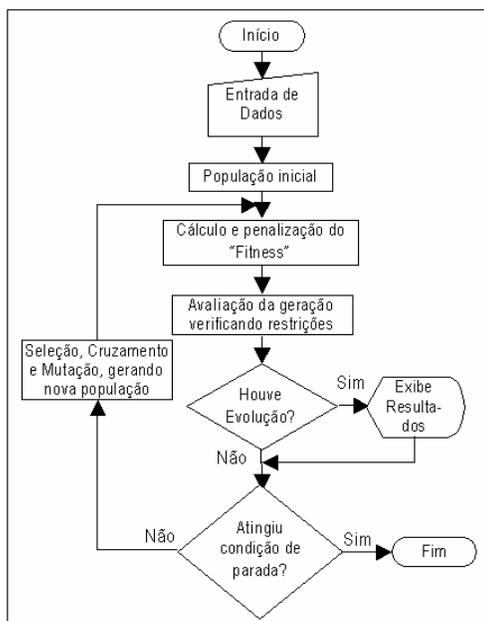


Figura 4. Fluxograma básico do protótipo “AG Optimizer”

Resultados e discussão

Nas restrições de rotação de culturas tem-se 3 restrições do tipo $h_j(\bar{X}) = x$. Restrições deste tipo

diminuem o espaço de soluções viáveis dificultando a otimização através dos métodos de otimização combinatória baseados em heurísticas.

Devido a este fato, implementou-se uma maneira de amenizar estas restrições adotando-se um valor de tolerância. Esta tolerância permite que a restrição seja flexibilizada, aumentando o espaço de soluções viáveis. Testes demonstraram que uma tolerância igual a 1 ha é suficiente para que o AG possa convergir satisfatoriamente.

Duas das três restrições financeiras também foram flexibilizadas, de forma que o AG convergisse. Testes demonstraram que após a convergência, as duas restrições acabavam por ser atendidas em sua forma original.

Realizaram-se 16 execuções sucessivas do protótipo “AG Optimizer”, onde se obteve os lucros apresentados na Figura 5. Os resultados completos são apresentados na Tabela 1. Os parâmetros genéticos foram assim configurados: número de indivíduos na população inicial = 128, taxa de cruzamento = 80%, taxa de mutação = 0,5%, número máximo de gerações estáticas = 800. Usou-se elitismo, pois percebeu-se que o protótipo não convergia para uma solução sem seu uso. Estipularam-se estes valores para os parâmetros genéticos após a execução de testes preliminares. Os valores citados fizeram o AG convergir para os melhores resultados.

A linha superior, de lucro R\$ 34.639,85, foi obtida através da resolução do PPL através do Método Simplex. A linha inferior, de lucro R\$ 31.377,64, representa o lucro obtido na safra de verão 98/99 e inverno 99.

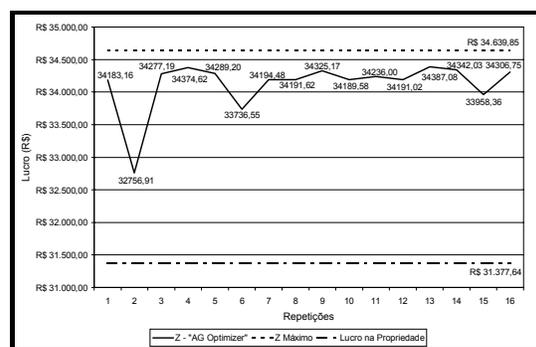


Figura 5. Lucros obtidos em 16 execuções sucessivas do protótipo “AG Optimizer”

PPLs são, deterministicamente, resolvidos através da Método Simplex. Aplicando este método ao problema originalmente proposto obteve-se os resultado apresentado na Tabela 2.

Tabela 1. Áreas atribuídas a 9 diferentes culturas em 16 execuções sucessivas do protótipo “AG Optimizer”

| ASN | ASP | AMN | AMS | AFA | AFS | AMA | AAV | ATR | Lucro (R\$) |
|--------|-------|--------|-------|-------|-------|--------|--------|--------|-------------|
| 13,560 | 6,250 | 10,060 | 6,250 | 0,060 | 0,000 | 12,940 | 9,810 | 14,060 | 34183,16 |
| 12,810 | 6,130 | 9,750 | 4,250 | 0,500 | 0,130 | 12,810 | 9,630 | 13,190 | 32756,91 |
| 13,440 | 6,630 | 9,940 | 6,310 | 0,000 | 0,000 | 13,060 | 9,130 | 13,000 | 34277,19 |
| 13,440 | 6,690 | 9,940 | 6,690 | 0,000 | 0,000 | 13,000 | 9,060 | 13,440 | 34374,62 |
| 13,560 | 6,560 | 10,000 | 6,000 | 0,000 | 0,000 | 12,940 | 9,380 | 13,810 | 34289,20 |
| 13,440 | 6,440 | 9,440 | 6,500 | 0,060 | 0,310 | 13,190 | 9,690 | 11,310 | 33736,55 |
| 13,440 | 6,560 | 9,690 | 6,630 | 0,000 | 0,000 | 13,190 | 9,000 | 11,880 | 34194,48 |
| 13,500 | 6,560 | 10,060 | 5,880 | 0,000 | 0,000 | 12,940 | 9,810 | 13,880 | 34191,62 |
| 13,500 | 6,630 | 10,060 | 6,130 | 0,000 | 0,060 | 12,880 | 9,310 | 14,380 | 34325,17 |
| 13,380 | 6,690 | 10,000 | 6,690 | 0,000 | 0,000 | 13,000 | 9,880 | 13,250 | 34189,58 |
| 13,560 | 6,500 | 10,060 | 5,940 | 0,000 | 0,000 | 12,940 | 9,880 | 14,000 | 34236,00 |
| 13,380 | 6,690 | 10,000 | 6,560 | 0,000 | 0,000 | 13,000 | 10,000 | 13,440 | 34191,02 |
| 13,690 | 6,750 | 9,690 | 5,810 | 0,000 | 0,000 | 12,940 | 9,630 | 14,060 | 34387,08 |
| 13,690 | 6,560 | 9,750 | 6,500 | 0,000 | 0,000 | 12,940 | 9,810 | 13,810 | 34342,03 |
| 13,130 | 7,000 | 10,000 | 5,440 | 0,000 | 0,000 | 12,880 | 10,190 | 14,310 | 33958,36 |
| 13,380 | 6,690 | 10,000 | 6,750 | 0,000 | 0,000 | 13,000 | 9,440 | 13,500 | 34306,75 |

Tabela 2. Áreas atribuídas a 9 diferentes culturas, através do método Simplex, para o modelo originalmente proposto

| ASN | ASP | AMN | AMS | AFA | AFS | AMA | AAV | ATR | Lucro (R\$) |
|--------|-------|-------|-------|-------|-------|--------|--------|--------|-------------|
| 13,331 | 6,665 | 9,998 | 6,619 | 0,000 | 0,000 | 13,006 | 10,002 | 13,373 | 34.142,08 |

A tolerância de 1 ha aplicada às restrições de rotação de culturas, mais a tolerância aplicada às restrições financeiras ampliam o espaço de soluções viáveis para o PPL. Aplicando-se o Método Simplex ao modelo “tolerado”, obteve-se o resultado apresentado na Tabela 3.

Tabela 3. Áreas atribuídas às 9 diferentes culturas, através do método Simplex, para o modelo “tolerado”

| ASN | ASP | AMN | AMS | AFA | AFS | AMA | AAV | ATR | Lucro (R\$) |
|--------|-------|-------|-------|-------|-------|--------|-------|--------|-------------|
| 13,935 | 6,468 | 9,701 | 6,467 | 0,000 | 0,000 | 12,897 | 9,038 | 14,333 | 34.639,85 |

Comparando os resultados obtidos pelo protótipo “AG Optimizer”, com o resultado obtido pelo Método Simplex, para o modelo “tolerado”, percebeu-se que o primeiro encontrou soluções que proporcionam lucro variando entre R\$ 32.756,91 e R\$ 34.387,08. Lucros inferiores ao proporcionado pela solução obtidas pelo Método Simplex que foi de R\$ 34.639,85, porém satisfatórios.

Este fato é justificado pela características próprias dos AGs, que são métodos de otimização que buscam uma solução ótima ou aproximadamente ótima para problemas de otimização combinatória.

O desempenho do protótipo “AG Optimizer”, quanto ao fator tempo, é insatisfatório em comparação ao Método Simplex. Em um computador padrão IBM-PC, com processador Intel Pentium 233 MHz, com 64 Mb de memória RAM, a execução do protótipo, até a convergência para uma solução, demanda mais de 16 minutos. O tempo de execução até a convergência não pode ser estimado com precisão, pois os AGs são algoritmos heurísticos.

O Método Simplex, implementado no software LINDO, demanda décimos de segundos para encontrar a melhor solução.

Conclusão

Conclui-se, como item principal, que os AGs podem ser utilizados na resolução do PPL proposto, de forma a otimizar o lucro obtido na propriedade agrícola estudada.

Para o modelo de Programação Linear proposto neste trabalho, o AG implementado obteve lucros que variaram entre R\$ 32.756,91 e R\$ 34.387,08. Entretanto, o AG não demonstrou ser o método mais eficiente na resolução destes problemas. O método mais eficiente é o Método Simplex que determinou, num espaço de tempo menor, um lucro de R\$ 34.639,85.

Os lucros obtidos pelo AG não deixam de ser interessantes, pois representam otimização do lucro obtido na propriedade. Originalmente, a propriedade proporcionava um lucro de R\$ 31.377,64, que é inferior ao menor valor de lucro encontrado pelo protótipo “AG Optimizer”.

Uma das principais vantagens dos AGs na resolução de POCs é que este algoritmo dispensa a necessidade de cálculos matemáticos complexos, fazendo com que sua implementação seja mais simples do que os métodos determinísticos comumente utilizados.

Agradecimentos

Os autores agradecem ao programa de Mestrado em Engenharia Agrícola da Universidade Estadual do Oeste do Paraná - Unioeste - e a Capes, pelo suporte financeiro proporcionado.

Referências

- BITTENCOURT, G. *Inteligência artificial: ferramentas e teorias*. Florianópolis: Editora da UFSC, 1998.
- CORTES, M. B. S. *Algoritmos genéticos em problemas de programação não linear contínua*. 1996. Tese (Doutorado) - Universidade Federal de Santa Catarina, Florianópolis, 1996.
- DAVIS, L. (Edt). *Handbook of Genetic Algorithms*. New York: Van Nostrand Reinhold, 1996.
- FEY, E. *et al.* Planejamento de um sistema agrícola utilizando programação linear: estudo de caso de uma propriedade do município de Maripá-PR. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 29, 2000, Fortaleza. *Anais...* CD-ROM, 2000.
- FILETO, R. Modelo de fazenda: automatizando o gerenciamento dos processos de produção em propriedades agrícolas diversificadas. 1997. Disponível em:

- <<http://www.agrosoft.com.br/ag97/papers/c3t1130.htm>>. Acesso em 15 jun. 2000.
- GOLDBARG, M. C.; LUNA, H. P. L. *Otimização combinatória e programação linear: modelos e algoritmos*. Rio de Janeiro : Campus, 2000.
- GOLDBERG, D. E. *Genetic algorithms in search, optimization & machine learning*. Reading: Addison-Wesley, 1989.
- HOLLAND, J. H. *Adaptation in natural and artificial systems*. Ann Arbor: University of Michigan Press, 1975.
- IBGE. *Dados históricos dos censos 1940-1996*. 1996. Disponível em: <http://www.ibge.gov.br/home/estatistica/populacao/censohistorico/1940_1996.shtm>. Acesso em 20 jun 2002.
- IBGE. *Censo demográfico 2000 - Resultados do Universo*. 2002. Disponível em: <<http://www.ibge.gov.br/home/estatistica/populacao/censo2000/tabelabrasil111.shtm>>. Acesso em 20 jun 2002.
- JOINES, J. A.; HOUCK, C. R. On the use of non-stationary penalty methods to solve nonlinear constrained optimization problems with GA's. In: 1994 IEEE CONFERENCE ON EVOLUTIONARY COMPUTATION, 1994, Orlando, *Proceedings...* Orlando: IEEE, 1994. p. 579-585,
- MARTIN, N. B. Custos: sistema de custo de produção agrícola. *Inf. Econ.*, São Paulo, v. 24, n. 9, p. 97-122, 1994.
- MENDES Fº, E. F. *Algoritmos Genéticos*. 1998. Disponível em: <<http://www.icmcs.sc.usp.br/~prico/gene1.html>>. Acesso em 20 mar. 2000.
- OLIVEIRA, A. J. *Um sistema inteligente de apoio à decisão para o planejamento de empresas rurais*. 1995. Dissertação (Mestrado) - Universidade Federal de Viçosa, Viçosa, 1995.
- RODRIGUES, L. H. A. *Planejamento estratégico de uma propriedade de leite através de um modelo de programação linear*. 1997. Disponível em: <<http://www.agrosoft.com.br/ag97/papers/c2a1630.htm>>. Acesso em 23 fev. 2000.
- SALOKHE, V. M.; PARIYAR, M. P. Optimum farm planning by linear programming for Tarai belt of Nepal. *Agricultural Mechanization in Asia, Afrik and Latin America*, Tokyo, v. 21, n. 4, p. 76-81, 1990.
- SHAMBLIN, J. E.; STEVENS JR.; G. T. *Pesquisa operacional: uma abordagem clássica*. 1. ed. São Paulo : Atlas, 1979.
- SHIMIZU, T. *Pesquisa operacional em engenharia, economia e administração: modelos básicos e métodos computacionais*. 1. ed. Rio de Janeiro : Guanabara Dois, 1984.
- YEPES, I. *Uma incursão aos algoritmos genéticos*. 2000. Disponível em <<http://www.geocities.com/igoryepes/>>. Acesso em 08 jun. 2000.

Received on March 06, 2002.

Accepted on July 08, 2002.