

Ferramenta para suporte à decisão de frentes de corte de cana-de-açúcar usando algoritmos genéticos

Trabalho de Conclusão de Curso

Engenharia da Computação

Carlos Eduardo Rodrigues de Alencar
Orientador: Prof. Renato Fernandes Corrêa

Recife, 2 de Julho de 2006

Carlos Eduardo Rodrigues de Alencar

**Ferramenta para suporte à decisão de
frentes de corte de cana-de-açúcar
usando algoritmos genéticos**

Resumo

O planejamento de colheita na cultura de cana-de-açúcar busca otimizar o retorno agrônomico, baseado no conceito de que a cana tem uma época, durante o ano, onde ocorre a máxima concentração de sacarose nos colmos. A definição do momento de acúmulo máximo de açúcares para o corte da cana de cada lote é de grande importância na produtividade da colheita.

Este trabalho apresenta uma solução para o problema de decisão de corte de lotes de cana-de-açúcar numa usina canavieira. Para isso foi desenvolvido um protótipo de software que utiliza Algoritmos Genéticos na otimização de uma função de retorno agrônomico envolvendo as variáveis:

- Pol (Porcentagem de sacarose aparente) no caldo da cana (PCC);
- TCH (Tonelada de cana por hectare);
- Fibra (Total de matéria seca após a moagem).

Foram realizadas várias simulações e obtidos valores padrão para os parâmetros do AG, a fim de obter um melhor desempenho do algoritmo para os estudos de casos utilizados neste trabalho.

A ferramenta possui uma interface amigável e fornece a um gerente agrícola a capacidade de ajustar a função de retorno agrônomico e de estabelecer restrições a fim de obter um conjunto de soluções otimizadas capaz de melhorar o retorno agrônomico e industrial na colheita.

Estas soluções visam auxiliar numa decisão mais eficaz de quais lotes colher, e assim dar suporte ao aumento do desempenho agrícola e industrial da atividade de cultivo da cana-de-açúcar.

Abstract

The harvest planning in sugarcane attempts to optimize agronomical gain. That was based on the concept that there is a peak of sugar levels a long the year, where happens the maximum concentration of sucrose in the stalks.

The definition of period that has maximum accumulation of sugar in the sugarcane is important in the productivity of the harvest.

This work presents a solution for the problem of harvest decision of plots cultivated with sugarcane in a sugarcane plantation. A software architecture was developed using genetic algorithms to optimize the agronomical gain. It involved the following variables:

- Pol (Apparent Percentage of sucrose) in the broth of the sugar cane (PCC);
- TCH (Ton of sugar cane for hectare);
- Fiber (Total of dry substance after the milling).

Several simulations were carried out and resulted values for the parameter of the genetic algorithm. The objective of these simulations were find a suitable set of parameters for the genetic algorithms.

The tool presents a friendly interface and supplies, for the production manager, the capacity to adjust the function of agronomical gain. It is also possible establish restrictions in order to get or set of optimized solutions capable to improve the agronomical and industrial gain in the harvest.

The proposed solution aims at assisting manners in more efficient decisions. This means to select which plots to harvest. Hence, it helps on increasing of the agricultural and industrial performances of the activity.

Sumário

Índice de Figuras	v
Índice de Tabelas	vi
Índice de Equações	vii
Capítulo 1 Introdução	9
1.1 Contexto	9
1.2 Descrição do Problema	10
1.2.1 Processo de Colheita da Cana-de-Açúcar	12
1.3 Organização Resumida	12
Capítulo 2 Computação Evolucionária e Algoritmos Genéticos	14
2.1 Histórico da Computação Evolucionária	14
2.2 Algoritmos Genéticos	16
2.2.1 Terminologia	16
2.2.2 Otimização	17
2.2.3 Princípios Básicos	20
2.2.4 Representação da População	21
2.2.5 Avaliação da Aptidão	21
2.2.6 Seleção	23
2.2.7 Elitismo	25
2.2.8 Cruzamento	25
2.2.9 Mutação	27
2.2.10 Parâmetros de um Algoritmo Genético	28
2.2.11 Teorema dos Esquemas (Schemata Theorem)	30
2.2.12 Hipótese dos Blocos Construtores (Building Blocks Hypothesis)	31
Capítulo 3 Metodologia	33
3.1 Codificação do Problema	33
3.2 Função Objetivo	34
3.3 Algoritmos Genéticos	35
3.3.1 Avaliação da Aptidão	36
3.3.2 Método de Seleção e Operadores Genéticos	36
3.3.3 Critério de Parada	36
3.3.4 Elitismo	36
3.4 Características Técnicas	37
3.4.1 Linguagem de Programação	37
3.4.2 Formato da Entrada	37
Capítulo 4 Desenvolvimento do Protótipo	38
4.1 Diagrama de Classes	38
4.2 Diagrama de Caso de Uso	39
4.3 Interface Gráfica	41
4.3.1 Menu Arquivo	41

4.3.2	Menu Parâmetros	42
4.3.3	Menu Visualizar	43
4.3.4	Menu Ajuda	44
Capítulo 5	Resultados Experimentais	46
5.1	Arquivo de Entrada	46
5.2	Estudos de Casos	46
5.2.1	Cana15	46
5.2.2	Cana380	47
5.3	Resultados	48
Capítulo 6	Conclusões e Trabalhos Futuros	50

Índice de Figuras

Figura 1. Ciclo da cana-de-açúcar e variações na temperatura e pluviosidade da região centro-sul do Brasil	11
Figura 2. Função Unimodal x Função Multimodal	18
Figura 3. Espaço de Busca	18
Figura 4. Representação gráfica de $f(x) = x_1^2 + x_2^2$	20
Figura 5. Estrutura básica de um AG típico	21
Figura 6. Posição do Cromossomo x Pressão de Seleção	23
Figura 7. Amostragem Universal Estocástica	24
Figura 8. Exemplo de Cruzamento com um ponto de Corte	26
Figura 9. Exemplo de Cruzamento com dois Pontos de Corte	26
Figura 10. Exemplo de Cruzamento Uniforme	27
Figura 11. Exemplo de Mutação	27
Figura 12. Planilha Eletrônica com informações de estimativas de PCC, TCH e Fibra.	37
Figura 13. Diagrama de Classes Simplificado do Protótipo de Software Desenvolvido	38
Figura 14. Diagrama de Casos de Uso do Protótipo de Software Desenvolvido.	39
Figura 15. Interface Principal do Protótipo de Software Desenvolvido.	41
Figura 16. Menu Otimização do Protótipo de Software Desenvolvido.	42
Figura 17. Menu Parâmetros do Protótipo de Software Desenvolvido.	42
Figura 18. Visualizar Relatório: Melhor Solução	43
Figura 19. Visualizar Gráfico: Função Objetivo	44
Figura 20. Menu Ajuda: Ajuda	44
Figura 21. Menu Ajuda: Sobre	45

Índice de Tabelas

Tabela 1. Exemplo de Problema de valores muito próximos de função objetivo resolvido com Ordenamento Linear	22
Tabela 2. Geração da População Inicial	28
Tabela 3. Exemplo de Esquemas	30
Tabela 4. Média Aritmética e Desvio Padrão para PCC, TCH e FIBRA da Tabela 9	47
Tabela 5. Média Aritmética e Desvio Padrão para PCC, TCH e FIBRA da Tabela 10	47
Tabela 6. Tabela com dados dos testes realizados	48
Tabela 7. Melhores soluções para os testes com a planilha Cana15.	48
Tabela 8. Melhores soluções para os testes com a planilha Cana380.	49
Tabela 9. Cana15	56
Tabela 10. Cana380	57

Índice de Equações

Equação 1. Exemplo de Função Linear	19
Equação 2. Primeira Restrição do Exemplo da Função Linear	19
Equação 3. Segunda Restrição do Exemplo da Função Linear	19
Equação 4. Exemplo de Função Não Linear	19
Equação 5. Primeira Restrição do Exemplo da Função Não Linear	19
Equação 6. Segunda Restrição do Exemplo da Função Não Linear	19
Equação 7. Função de Ordenamento Linear	22
Equação 8. Função de Ordenamento Exponencial	23
Equação 9. Função de Ordenamento Exponencial Normalizada	23
Equação 10. Número esperado de m' cópias do Esquema H	31
Equação 11. Função Multiobjetivo que se deseja maximizar para decisão de seleção de lotes a cortar	34
Equação 12. Função que determina o valor de PCC total	34
Equação 13. Função que determina o valor de Fibra total	34
Equação 14. Restrição para a Tonelagem que se deseja cortar	35
Equação 15. Tonelagem Estimada	35
Equação 16. Restrição para o número de lotes a cortar	35

Agradecimentos

Para que um trabalho como este se concretize é preciso a conjunção de certos elementos como: tempo, esforço, vontade, cuidado, dedicação, além de uma dose de preocupação. Tudo isto requer a cooperação integrada de várias pessoas, que só resta agradecer afetuosamente.

A Deus porque sem ele nada disso seria possível.

Aos meus pais, Cícero de Alencar Sobriera e Lissandra Maria Rodrigues de Alencar que me criaram com muito amor, ensinaram todos os valores morais, me apoiaram e deram condições para que hoje eu possa estar concluindo um dos meus projetos de vida.

Aos meus amigos George Gomes Cabral, Glenda Gomes Cabral e Érika Gomes Cabral que são como uma família para mim.

De forma especial e com muito amor, a minha namorada Hilda, pelo apoio e compreensão, principalmente nos momentos difíceis.

Ao meu Orientador Renato Fernandes Corrêa que com muita paciência me encaminhou para o fim desse projeto.

A todos meus familiares e amigos que contribuíram de alguma forma durante toda essa jornada.

Capítulo 1

Introdução

1.1 Contexto

Sobretudo nas últimas décadas, o setor agroindustrial canavieiro iniciou um processo de pesquisa e desenvolvimento que garante seu destaque no setor agrícola brasileiro. As usinas de cana-de-açúcar procuram se adequar ao cenário da economia nacional por meio de inovações como a melhor forma de integrar as áreas agrícola e industrial. A necessidade da implantação de alternativas de técnicas, equipamentos e recursos que beneficiem o planejamento e o controle do processo produtivo ocorre em razão do aumento de competitividade no setor [38].

No Brasil são cultivados, atualmente, cerca de 4,2 milhões de hectares com a cana-de-açúcar. Nosso país participa com cerca de 25% da produção mundial, seguido pela Índia (20%) e China (6%). Com a implantação do Proálcool, o maior programa de combustível renovável do mundo, a cultura da cana-de-açúcar passou a assumir um papel ainda maior no aspecto social, econômico e ambiental [12].

Este trabalho tem como motivação básica contribuir com uma efetiva melhoria na atividade agrícola da cana-de-açúcar e também como uma continuação dos trabalhos do Intelicolheita [30][36], dada sua grande importância sócio-econômica da cultura tanto para a economia regional quanto nacional, auxiliando no processo decisório de colheita das áreas cultivadas mais adequadas.

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 agrônômica, como também outros aspectos industriais, com o intuito de reduzir custos operacionais e de demandas energéticas.

A principal contribuição deste trabalho compreende numa aplicação de inteligência artificial [32], mais especificamente Algoritmos Genéticos Binários [25], voltada para a otimização do corte de cana-de-açúcar de uma unidade industrial para o período anual de uma safra.

Algoritmos Genéticos são eficientes na busca de soluções otimizadas, ou aproximadamente ótimas, numa grande variedade de problemas, dado que não possuem diversas das limitações encontradas nos métodos tradicionais de busca.

Como resultado do uso da ferramenta desenvolvida neste trabalho se tem um conjunto de lotes a cortar quem possuam uma maior concentração de sacarose que os demais lotes de uma unidade agrícola. Isto é, serão indicados os lotes a cortar que possuam os melhores índices de PCC, TCH e Fibra dada uma configuração inicial de lotes de um dos vários engenhos de uma usina e restrições impostas pelo usuário no processo decisório.

Estas configurações e restrições estão relacionadas respectivamente aos parâmetros de otimização e ao espaço de soluções factíveis impostas pelas restrições. Estes conceitos serão apresentados detalhadamente no capítulo 2 no subtópico otimização.

As restrições mais comumente conhecidas abrangem diversos fatores [29], tais como:

- Grandes extensões de terra agricultável;
- As decisões, geralmente, envolvem implicitamente muitas análises de custo e benefício;
- Várias decisões são tomadas em tempo exíguo;
- Diversidade de fatores a considerar no processo decisório como:
 - Capacidade de moagem,
 - Programação de corte das frentes de trabalho,
 - Análises de campo em pré-colheita: TCH, PCC e Fibra (Estas variáveis serão descritas na seção 1.2.1).

O objetivo deste trabalho consiste na seleção dos melhores lotes de cana-de-açúcar de uma unidade produtora de açúcar ou álcool que atenda da melhor forma ao conjunto de critérios especificados, propiciando um resultado mais eficaz em termos de retorno para a empresa agrícola, dadas as restrições acima especificadas.

1.2 Descrição do Problema

O planejamento de colheita na cultura de cana-de-açúcar busca otimizar o retorno agrônomico, baseado no conceito que a cana tem uma época, durante o ano, onde ocorre a máxima concentração de sacarose nos colmos. Essa época pode ser visualizada na Figura 1, na fase de maturação.

Na fase de maturação, a cana-de-açúcar atinge seu tamanho máximo, é quando se inicia o período seco. A cana quando estimulada pela diminuição de água no solo passa a acumular energia, açúcares, a fim de subsidiar o período seco.

Após a época da maturação é desencadeado o processo de reprodução onde as reservas de açúcares serão utilizadas, fazendo com que haja perda de produtividade na colheita.

Dessa forma, a definição da melhor época para o corte da cana de cada lote, isto é do momento de acúmulo máximo de açúcares, é de grande importância econômica.

Castro (1999)[8], descreve que a curva que caracteriza o crescimento da cana-de-açúcar de primeiro corte é simétrica para cana de ano mostrando-se bimodal em cana de ano e meio (Figura 1).

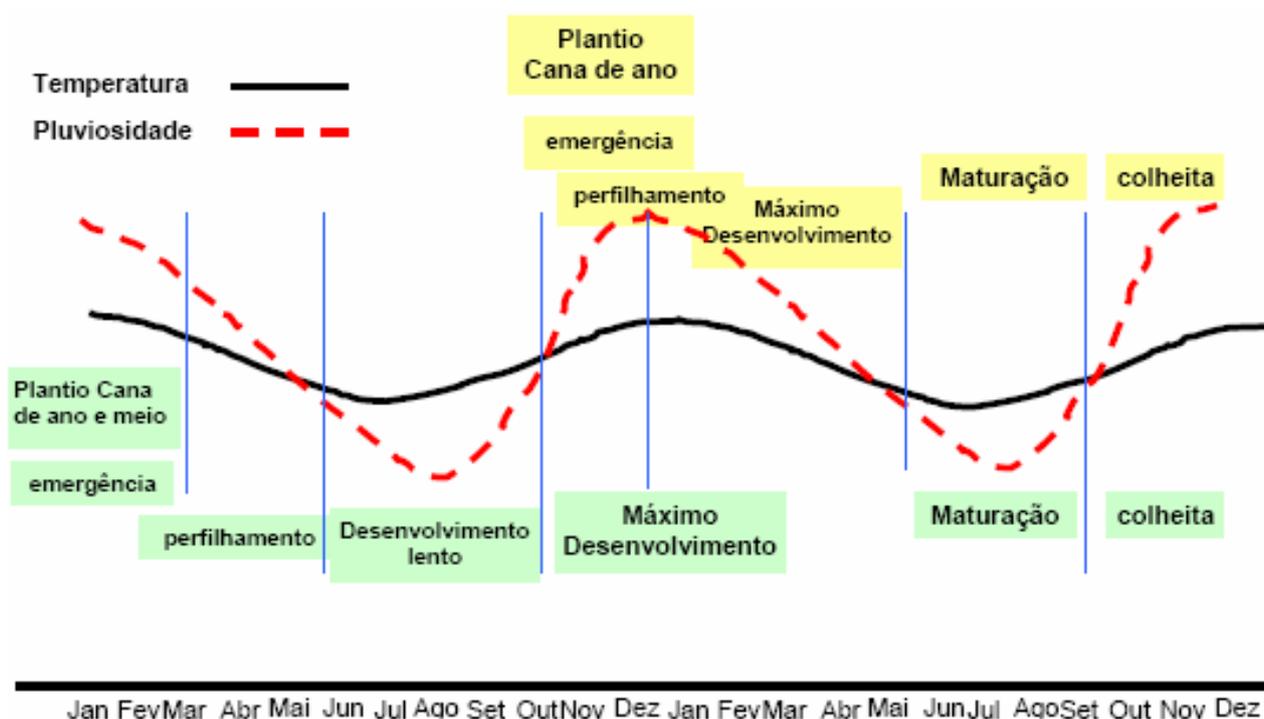


Figura 1. Ciclo da cana-de-açúcar e variações na temperatura e pluviosidade da região centro-sul do Brasil [8].

O acúmulo de açúcares apresentado na Figura 1 pode ser dividido em três fases[26]:

- I. Fase inicial, na qual o crescimento é lento;
- II. Fase de rápido crescimento, onde 70% a 80% dos açúcares é acumulado;
- III. Fase final, onde o crescimento é novamente lento, acumulando cerca de 10% dos açúcares.

Nesse sentido, para que se obtenha um maior acerto na decisão agrícola da colheita da cana-de-açúcar se faz necessária a existência de um sistema que auxilie no processo decisório de corte de lotes plantados. Alguns fatores comuns observados nesta prática agrônômica e que dificultam a tomada de decisão de que lotes cortar são:

- Quantidade de lotes a cortar de uma unidade agrícola;
- Tempo exíguo para um grande número de decisões;

O emprego de algoritmos genéticos no suporte à decisão gerencial provê uma efetiva melhoria na atividade agrícola em questão. Esta melhoria decorre, simplesmente, de um auxílio mais efetivo do sistema nas decisões de colheitas.

Convenientemente orientados sobre as áreas cultivadas de cana-de-açúcar mais favoráveis para a colheita e adequadas aos demais aspectos do negócio, o uso do sistema proporciona às decisões maior velocidade, efetividade e clareza.

1.2.1 Processo de Colheita da Cana-de-Açúcar

No Brasil, devido a grande extensão do seu território, encontram-se as mais variadas condições climáticas para a lavoura canavieira. Possuindo duas estações distintas durante o ano, o Brasil possivelmente é o único país no mundo com duas colheitas anuais: uma do Norte ao Nordeste, que começa em setembro e continua até abril, e outra na região Sul que vai de junho a dezembro[5].

O processo de decisão de colheita é a macro-atividade em que técnicos, engenheiros agrônomos, decidem pelo momento ideal de se colher as áreas cultivadas com as diversas variedades de cana-de-açúcar.

De acordo com Buarque[29] em sua dissertação, três indicadores podem ser utilizados para a avaliação do desempenho econômico em função de suas efetivas contribuições para a decisão de colheita:

- TCH (Tonelada de Cana por Hectare) – Para garantia de volumes de produção;
- PCC (Porcentagem aparente de açúcar no Caldo da Cana) – Para medição da qualidade da matéria prima (quantidade de açúcares);
- Fibra – Para medição da qualidade do potencial calorífico produzido pela queima do bagaço de cana-de-açúcar nas caldeiras após sua moagem.

1.3 Organização Resumida

Este presente trabalho se encontra assim estruturado:

- Introdução
 - *Capítulo 1 – Contexto, Descrição do Problema e Organização Resumida*
- Introdução ao tema, descrição detalhada do problema a ser solucionado e uma breve apresentação sobre o processo de colheita.
- Fundamentação
 - *Capítulo 2 – Computação Evolucionária e Algoritmos Genéticos*
- Este capítulo apresenta uma visão geral de Computação Evolucionária e de forma mais aprofundada, Algoritmos Genéticos.
- Contribuição
 - *Capítulo 3 – Metodologia*
- Este capítulo tem como objetivo apresentar a metodologia de desenvolvimento do software proposto.
 - *Capítulo 4 – Resultados Experimentais*
- Este capítulo apresenta o protótipo de software desenvolvido e os resultados obtidos por ele.

- *Capítulo 5 – Desenvolvimento do Protótipo*
 - Este capítulo apresenta testes realizados com o protótipo de software desenvolvido neste trabalho.
- Conclusão
 - *Capítulo 6 – Conclusão e Trabalhos Futuros*
 - Este capítulo apresenta a conclusão e uma abordagem a trabalhos futuros.

Capítulo 2

Computação Evolucionária e Algoritmos Genéticos

2.1 Histórico da Computação Evolucionária

A Computação Evolucionária é um ramo de pesquisa emergente da Inteligência Artificial que propõe um novo paradigma para solução de problemas inspirado na Seleção Natural. Teve como fonte de inspiração os mecanismos de evolução de populações de seres vivos. Segue o princípio de seleção natural e sobrevivência do mais apto, declarado em 1859 pelo naturalista e fisiologista inglês Charles Darwin [9] em seu livro “A Origem das Espécies”. De acordo com Charles Darwin, “Quanto melhor um indivíduo se adaptar ao seu meio ambiente, maior será sua chance de sobreviver e gerar descendentes”.

A computação Evolucionária compreende um conjunto de técnicas de busca e otimização inspiradas na evolução natural das espécies. Desta forma, cria-se uma população de indivíduos que vão reproduzir e competir pela sobrevivência. Os mais adaptáveis sobrevivem e transferem suas características a novas gerações.

A Computação evolucionária tem como base quatro áreas [2]:

- Estratégias evolucionárias:
 - Em 1964 e 1965, Ingo Rechenberg [32] e seu colega Hans-Paul Schwefel [34], da Universidade Técnica de Berlim, idealizaram a metodologia e batizaram-na de Estratégias Evolucionárias, para resolver problemas técnicos de otimização de perfis aerodinâmicos. Hoje, após diversas modificações, a sistemática é empregada em muitos problemas de otimização com variáveis reais, pois necessita de pouca informação sobre o problema, não incorrendo em derivadas da função a otimizar, e sendo aplicável a modelos tanto lineares como não lineares.
- Programação evolucionária:
 - Um ano depois da publicação de Rechenberg, o paradigma Programação Evolucionária foi desenvolvido por L. J. Fogel, A.J. Owens e M.J. Walsh [17]. O problema inicialmente tratado nesta metodologia era o de evoluir máquinas de estado finito para predição de símbolos. A aptidão de cada máquina era medida pelo número de símbo-

los corretamente previsto pela mesma, sendo que cada genitor originava, por mutação, um descendente. Dentre os ascendentes e descendentes, os melhores 50% eram escolhidos para continuar o processo na próxima iteração. O campo de aplicação desta metodologia é especialmente aquele em que a superfície de solução da função de aptidão é muito acidentada, com muitos pontos de ótimos locais.

- Algoritmos genéticos:
 - Os Algoritmos Genéticos, foram desenvolvidos a partir dos trabalhos de pesquisa de John Holland, que, desde o início da década de 60, esteve preocupado com o estudo da formalização de processos adaptativos da natureza, simulando sistemas que recebiam informações sensoriais do meio ambiente através de detectores binomiais [21]. Apresentou algoritmos genéticos em 1975 na sua publicação: "*Adaptation in Natural and Artificial Systems*" [22] onde salientou a aplicabilidade dos Algoritmos Genéticos a problemas de economia, jogos, reconhecimento de padrões e otimização de parâmetros. K. de Jong [23] estendeu e aprofundou a técnica para o uso específico da otimização. Foi finalmente popularizado por David E. Goldberg [18], aluno de Holland, nos anos 80 que obteve seu primeiro sucesso em aplicação industrial com Algoritmos Genéticos.
- Programação genética:
 - É uma técnica de geração automática de programas de computador criada por John Koza em 1992 [24], este método, a partir de uma população inicial de programas, procura evoluir outros que, quando executados supostamente devem resolver o problema em questão. Geralmente eles são representados por uma árvore sintática, e não por linhas de código, como os construídos em linguagens declarativas. Sendo a Linguagem LISP bem adaptada para representar as estruturas de árvores e para implementar a modelagem dos operadores de mutação e recombinação, é a mais utilizada neste paradigma de Computação Evolucionária.
 - As aplicações existentes em Programação Genética se relacionam com as áreas de planejamento, compressão de imagens, robótica e controle.

Neste trabalho foi utilizado Algoritmos Genéticos na busca por uma solução otimizada do problema do corte da cana-de-açúcar. Devido algumas vantagens, como:

- Trabalham com uma codificação do conjunto de parâmetros e não com os próprios parâmetros;
- A simplificação na formulação e solução do problema trabalhando-se com descrições de entrada formadas por cadeias de bits de tamanho fixo;
- Utilizam informações de custo e recompensa e não derivadas ou outro conhecimento auxiliar.
- Por possuírem um paralelismo implícito decorrente da avaliação independente de cada uma dessas cadeias de bits, ou seja, pode-se avaliar a viabilidade de um conjunto de parâmetros para a solução do problema de otimização em questão;
- Tem um bom desempenho garantido pelo teorema dos Esquemas, Segundo Goldberg[18], pequenos esquemas contidos em bons cromossomos (i.e. aqueles com aptidão acima da média) aumentam exponencialmente nas gerações seguintes, ao passo que esquemas contidos em cromossomos ruins (i.e. aqueles com a aptidão abaixo da média) tendem a desaparecer nas gerações seguintes.

2.2 Algoritmos Genéticos

Algoritmos Genéticos, AGs, são métodos de otimização global, baseados nos mecanismos de seleção natural. Empregam uma estratégia de busca paralela e estruturada, mas aleatória, que é voltada em direção ao reforço da busca de pontos de “alta aptidão”, ou seja, pontos nos quais a função a ser minimizada/maximizada tem valores relativamente baixos/altos.

Apesar de aleatórios, os AGs não utilizam passos aleatórios não direcionados, pois exploram informações históricas para encontrar novos pontos de busca onde são esperados melhores resultados. Isto é feito através de processos iterativos, onde cada passo da iteração é chamada de geração.

Os AGs são métodos de otimização eficientes por utilizar duas técnicas denominadas *Exploration* e *Exploitation* para encontrar o ótimo global da função a ser minimizada/maximizada [6]. Ambas as técnicas têm a mesma tradução para o português, exploração. Entretanto, *Exploitation* significa exploração no sentido de absorver informações presentes nas soluções encontradas e *Exploration* diz respeito à exploração de busca à procura por novas soluções.

2.2.1 Terminologia

Na biologia, a teoria da evolução diz que o meio ambiente seleciona, em cada geração, os seres vivos mais aptos de uma população para sobrevivência. Como resultado, somente os mais aptos conseguem se reproduzir, uma vez que os menos adaptados geralmente são eliminados antes de gerarem descendentes. Durante a reprodução, ocorrem fenômenos como mutação e *crossover* (cruzamento), entre outros, que atuam no material genético armazenado nos seres vivos na população. Sobre esta população diversificada age a seleção natural, permitindo a sobrevivência dos seres mais adaptados.

Um AG é a metáfora desses fenômenos, o que explica porque AGs possuem muitos termos originados da biologia.

Os principais termos encontrados na literatura são:

- Cromossomo:
 - Na biologia, é uma cadeia de genes.
 - No AG, é uma cadeia de bits que representa uma possível solução para o problema em questão.
- Gene:
 - Na biologia, é a unidade de hereditariedade que é transmitida pelo cromossomo e que controla as características do organismo.
 - No AG, é um parâmetro codificado no cromossomo, ou seja, um elemento do vetor que representa o cromossomo.
- Indivíduo:
 - Na biologia, é um simples membro da população.
 - No AG, um indivíduo é formado pelo cromossomo e sua aptidão.
- Genótipo:
 - Na biologia, representa a composição genética contida no Genoma.
 - No AG, representa a informação contida no cromossomo.

- Fenótipo:
 - Na biologia, é o conjunto das características perceptíveis de um indivíduo, é o resultado da sua interação com o genótipo com o ambiente.
 - Nos Algoritmos Genéticos, representa o objeto, estrutura ou organismo construído a partir das informações do genótipo. É o cromossomo decodificado
- Alelo:
 - Na biologia, representa uma das formas alternativas de um gene.
 - No AG, representa os valores que o gene pode assumir. Por exemplo, um gene que representa o parâmetro cor de um objeto poderia ter o alelo azul, preto, verde, etc.

2.2.2 Otimização

Otimização é à busca da melhor solução para um dado problema. Consiste em encontrar a solução que corresponda ao ponto máximo ou mínimo de uma função $f(x,y,z, \dots)$ de n parâmetros, (x,y,z, \dots) .

Os principais conceitos sobre a metodologia de otimização são:

- Função objetivo: equação matemática que representa o que se deseja melhorar em um dispositivo. Tem como sinônimos: critério de otimização, função custo ou ainda função de mérito (*fitness function*);
- Parâmetros: correspondem às variáveis da função objetivo. São ajustados durante o processo de otimização visando obter a(s) solução(ões) ótima(s). Podem ser chamados de variáveis de otimização, variáveis objeto, variáveis de concepção ou de projeto (*design variables*);
- Espaço de busca: domínio (delimitado ou não) que contém os valores dos parâmetros. Corresponde ao espaço de soluções. A dimensão do espaço de busca é definida pelo número de parâmetros envolvidos nas soluções (por exemplo, se cada solução é formada por três parâmetros, o espaço de busca é tridimensional). É também conhecido como espaço de parâmetros ou ambiente;
- Restrições: especificações do problema que delimitam os espaços de parâmetros e/ou que não permitem determinada faixa de valores nos objetivos;

A Figura 2 apresenta dois gráficos, o primeiro unimodal, onde o $f(x)$ é mínimo em x_0 . O segundo gráfico, multimodal, apresenta dois pontos de valor mínimo, x_0 e x_1 . O ponto x_0 é denominado de mínimo local, pois $f(x_0) \leq f(x)$ para todo x suficientemente próximo de x_0 . O ponto x_1 é denominado de mínimo global, pois $f(x_1) \leq f(x)$ para todos os valores que x possa assumir. Algumas técnicas de otimização como Subida de Encosta e Métodos Analíticos possuem dificuldades para decidir se um dado ponto ótimo é local ou global.

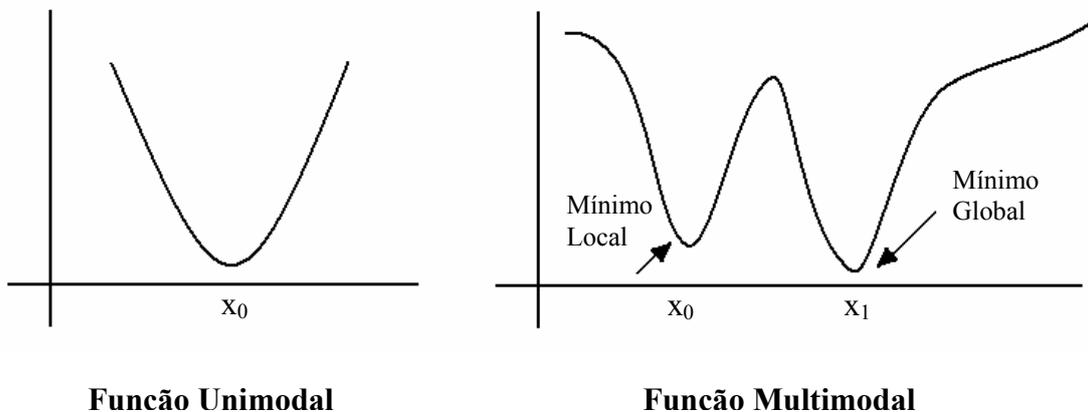


Figura 2. Função Unimodal x Função Multimodal, Adaptado de [25]

O espaço de busca é dividido em região factível e região não-factível. A região factível é o conjunto onde se encontram as possíveis soluções que satisfazem a todas as restrições do problema, inclusive as soluções ótimas.

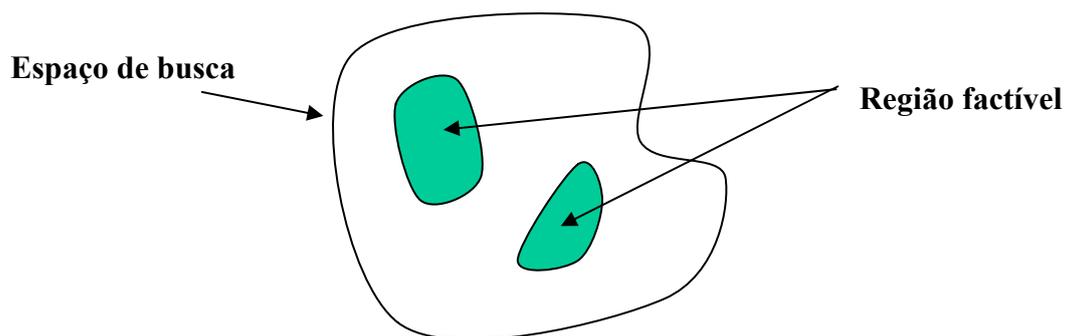


Figura 3. Espaço de Busca

Quanto ao critério de restrição, os parâmetros da função objetivo podem ser restritos ou irrestritos. As restrições podem aparecer em forma de equações, como:

Minimizar $f(x,y)$ sujeito a $x^2 + y^2 = 5$;

Ou na forma de inequações:

Minimizar $f(x,y)$ sujeito a $x^2 + y^2 \leq 5$.

Quando o conjunto factível é \mathcal{R}^n , tem-se um problema de otimização irrestrito.

Os problemas de otimização de funções objetivo podem ser:

- Problema de Programação Linear: É uma função linear, a ser minimizada ou maximizada, sujeita as restrições também lineares. A Equação 1 mostra um exemplo de um problema de programação linear restrita pelas Equações 2 e 3:

Minimizar:

$$f = \sum_{i=1}^n c_i x_i$$

Equação 1. Exemplo de Função Linear

Sujeito a:

$$\sum_{i=1}^n a_{ij} x_i - b_j \geq 0 \quad j = 1, \dots, m$$

Equação 2. Primeira Restrição do Exemplo da Função Linear

$$x_i \geq 0 \quad i = 1, \dots, n$$

Equação 3. Segunda Restrição do Exemplo da Função Linear

- Problema de Programação não Linear: Quando a função objetivo ou as restrições são funções não lineares dos parâmetros. A Equação 4 mostra um exemplo de um problema de programação não linear restrita pelas Equações 5 e 6:

Minimizar:

$$f(x) = x_1^2 + 2x_2^2$$

Equação 4. Exemplo de Função Não Linear

Sujeito a:

$$x_1 + x_2 = 2$$

Equação 5. Primeira Restrição do Exemplo da Função Não Linear

$$x_1, x_2 \geq 0$$

Equação 6. Segunda Restrição do Exemplo da Função Não Linear

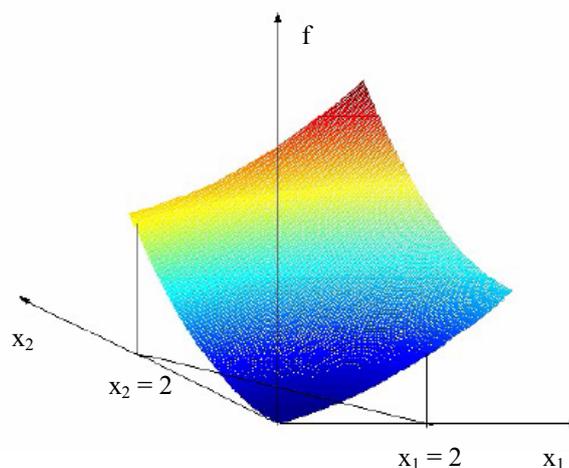


Figura 4. Representação gráfica de $f(x) = x_1^2 + x_2^2$

Os parâmetros da função objetivo também podem ser classificados como contínuos que possuem um número infinito de soluções ou discretos que apresentam um número finito de possíveis soluções, em geral, resultantes de uma combinação de parâmetros discretos.

2.2.3 Princípios Básicos

A idéia básica do funcionamento de um AG é a de tratar as possíveis soluções do problema como indivíduos de uma população que irá evoluir ao longo das gerações, iterações do AG. A execução do AG pode ser definida nos seguintes passos:

- O primeiro passo de um AG típico é a geração de uma população inicial de cromossomos, estes cromossomos por sua vez representam possíveis soluções do problema a ser resolvido.
- Durante o processo evolutivo, esta população é avaliada e cada cromossomo recebe uma nota, denominada de aptidão, refletindo a qualidade da solução que ele representa em relação à função objetivo.
- Em seguida, através de um operador de seleção os cromossomos mais aptos são selecionados para uma nova geração e os menos aptos são descartados.
- Os indivíduos selecionados podem sofrer modificações em suas características fundamentais através dos operadores de cruzamento e mutação gerando descendentes para a próxima geração.
- Este processo é repetido até que uma solução satisfatória seja encontrada.

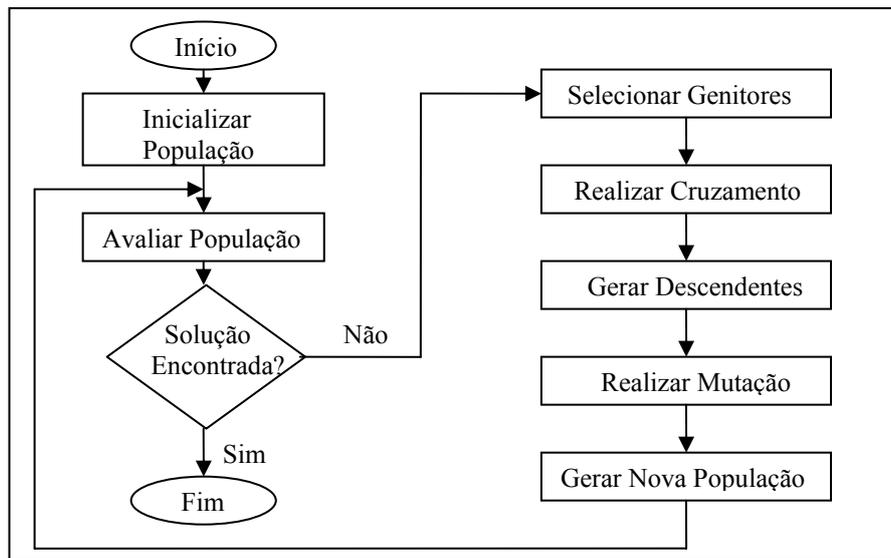


Figura 5. Estrutura básica de um AG típico

2.2.4 Representação da População

Um AG trabalha com populações de cromossomos. A população de um AG é o conjunto de indivíduos que estão sendo cogitados como uma solução e que serão usados para criar o novo conjunto de indivíduos para análise.

Existem diversas maneiras de se representar um indivíduo em um algoritmo genético. A principal, mais simples e mais comumente usada, é a representação em cadeia binária com um tamanho fixo, a qual usaremos na resolução do problema deste estudo. Nela, cada indivíduo é representado por uma seqüência de tamanho fixo composta por bits que assumem valor 0 ou 1 [20].

A população é formada por um conjunto finito de indivíduos, sendo que seu tamanho é um dos parâmetros do AG e é fixo durante todas as gerações. Pode-se defini-la como uma matriz $n \times m$, considerando n o tamanho da população e m o tamanho de cada indivíduo (seu tamanho em bits). Cada linha da matriz representa um indivíduo distinto.

O tamanho da população pode afetar o desempenho global e a eficiência dos algoritmos genéticos. Populações muito pequenas têm grandes chances de perder a diversidade necessária para convergir a uma boa solução, pois fornecem uma pequena cobertura do espaço de busca do problema. Entretanto, se a população tiver muitos indivíduos, o algoritmo poderá perder grande parte de sua eficiência pela demora em avaliar a função de aptidão de todo o conjunto a cada iteração, além de ser necessário trabalhar com maiores recursos computacionais.

2.2.5 Avaliação da Aptidão

Após a definição da codificação das soluções candidatas do problema, a segunda grande decisão, segundo Mitchell [28], diz respeito à forma como os cromossomos serão selecionados ou reproduzidos, para posteriormente sofrerem as operações de cruzamento e mutação, e conseqüentemente gerar os novos descendentes.

Na medição proporcional simples [18], os valores associados aos indivíduos de uma população dependem dos valores da função objetivo $f(x)$.

O valor da função objetivo nem sempre é adequado para ser utilizado como valor de aptidão. Podem ocorrer alguns problemas como:

- Os valores podem ser muito próximos, o que tornaria a seleção aleatória;
- Alguns valores podem ser muito elevados em relação ao resto da população, causando um problema conhecido como convergência prematura, em especial, quando a média das medidas do desempenho dos indivíduos da população se aproximar das medidas do desempenho dos melhores indivíduos. Quando isto acontece, os melhores indivíduos e os indivíduos com medidas de desempenho próximas da média terão aproximadamente a mesma probabilidade de se reproduzirem e gerar descendentes, o que poderá conduzir o processo de procura a um máximo/mínimo local.

O mapeamento da função objetivo para o valor da aptidão pode ser feito de vários modos, dois dos quais serão discutidos a seguir.

Ordenamento Linear

No método ordenamento linear, a aptidão é dada pela Equação 7[3]:

$$f(x) = \text{Min} + (\text{Max} - \text{Min}) \frac{N - i}{N - 1}$$

Equação 7. Função de Ordenamento Linear

Em que i é o índice do cromossomo na população em ordem decrescente de valor da função objetivo. Normalmente é utilizado $1 \leq \text{Max} \leq 2$ e $\text{Max} + \text{Min} = 2$. Vale notar que deste modo a aptidão representa o número de filhos esperados do cromossomo e $\text{Max} - \text{Min}$ representa a pressão de seleção (razão entre a maior aptidão e a aptidão média, f_{max} / f).

Um exemplo mostrado na Tabela 1, que expande o intervalo dos valores da função objetivo que estão muito próximos:

Tabela 1. Exemplo de problema de valores muito próximos de função objetivo resolvido com Ordenamento Linear

Cromossomo	Função Objetivo	Posição	Aptidão	Probabilidade de seleção
A	2.000,999588	1	2.0	40%
B	2.000,826877	2	1.5	30%
C	2.000,655533	3	1.0	20%
D	2.000,400148	4	0.5	10%
E	2.000,102002	5	0.0	0%

A Figura 6 mostra o controle da pressão de seleção utilizando ordenamento linear. Na Figura 6 (a), a alta pressão de seleção favorece fortemente os melhores cromossomos, direcionando a busca às melhores soluções encontradas até então (muito *exploitation*). Na Figura 6 (b), a baixa pressão de seleção favorece um pouco mais os cromossomos de baixa aptidão, direcionando a busca para regiões desconhecidas do espaço de busca (muito *exploration*).

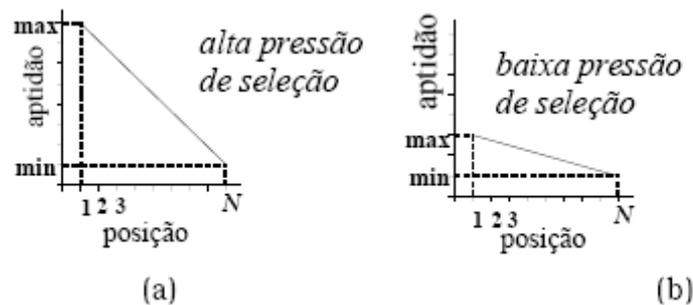


Figura 6. Posição do Cromossomo x Pressão de Seleção

Ordenamento Exponencial

No método ordenamento exponencial, a aptidão é dada pela Equação 8 [27]:

$$f_i = q(1 - q)^{i-1}$$

Equação 8. Função de Ordenamento Exponencial

Em que $q \in [0, 1]$ e i é o índice do cromossomo na população em ordem decrescente de valor da função objetivo. Alternativamente, a aptidão pode ser normalizada dividindo a Equação 8 pelo fator $1 - (1 - q)^N$. O ordenamento exponencial (Equação 9) permite maior pressão de seleção do que o ordenamento linear.

$$f_i = \frac{q(1 - q)^{i-1}}{1 - (1 - q)^N}$$

Equação 9. Função de Ordenamento Exponencial Normalizada

2.2.6 Seleção

Como os algoritmos genéticos são baseados na teoria da evolução, a cada nova geração, eles devem ser capazes de identificar os indivíduos mais adaptados da geração anterior e os manter na população, excluindo, em contra partida, os indivíduos menos adaptados.

Dada uma população em que a cada indivíduo foi atribuído um valor de aptidão, existem vários métodos para selecionar os indivíduos sobre os quais serão aplicados os operadores genéticos. Há diversas formas de seleção, entre elas as mais frequentemente utilizadas são os métodos de seleção por Torneio e a Amostragem Estocástica Universal.

Seleção por Torneio

Na seleção por torneio, cada cromossomo é selecionado para a população intermediária do seguinte modo:

- São escolhidos aleatoriamente, com probabilidades iguais, n cromossomos da população e o melhor dentre estes cromossomos é selecionado.
- O valor $n = 2$ é usual. A seleção por torneio não precisa de escalonamento da aptidão e nem de ordenamento.

Em uma outra versão, a seleção por torneio utiliza probabilidades diferenciadas. Se o torneio envolve dois cromossomos, o primeiro ganha o torneio com probabilidade q (onde $0,5 < q < 1$); e o segundo, com probabilidade $1 - q$. Para um torneio entre n cromossomos, o primeiro cromossomo ganha o torneio com probabilidade q , o segundo com probabilidade $q(1 - q)$; o terceiro, com $q(1 - q)^2$, e assim por diante... (vale notar que se $n = N$, em que N é o tamanho da população, tal seleção é equivalente à seleção com ordenamento exponencial).

Aumentando o número n de cromossomos do torneio ou a probabilidade q do primeiro cromossomo vencer, aumenta-se a pressão de seleção, isto é, cromossomos com aptidão acima da média terão mais chances de serem selecionados.

Amostragem Estocástica Universal

O algoritmo Roda da Roleta possui o problema de apresentar uma grande variância em relação ao número esperado de filhos dos cromossomos pais. A Amostragem Estocástica Universal ou SUS do inglês, *Stochastic Universal Sampling* [3], soluciona este problema de maneira simples e tão perfeita quanto possível.

Neste método, a população é embaralhada e um gráfico do tipo “torta” é construído com uma fatia associada a cada cromossomo da população. A área das fatias é proporcional à aptidão do cromossomo que ela representa. Em volta da parte externa da “torta” são colocados N ponteiros igualmente espaçados. Por fim, o cromossomo apontado por cada ponteiro é selecionado para cruzamento e mutação.

Na prática, os cromossomos selecionados podem ser alocados em uma população intermediária e então, a cada dois cromossomos é aplicado o cruzamento.

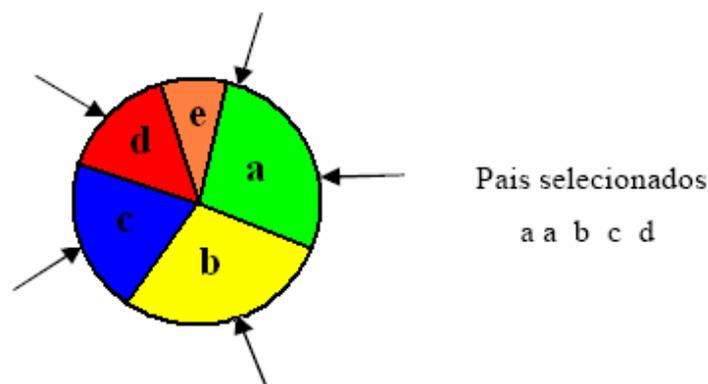


Figura 7. Amostragem Universal Estocástica

2.2.7 Elitismo

O Elitismo foi proposto por DeJong [23], um dos trabalhos pioneiros sobre AG, consiste em fazer o AG reter sempre, ao menos, uma cópia do melhor indivíduo para a próxima geração, dessa forma, evita-se que os k melhores indivíduos sejam destruídos pelas operações de cruzamento e mutação.

Na substituição dos indivíduos por seus descendentes com elitismo, os k melhores pais nunca são substituídos por filhos piores. Geralmente é utilizado um valor de $k = 1$. Aumentando o valor de k , aumenta-se o risco da convergência prematura.

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 de estagnação em um máximo local.

2.2.8 Cruzamento

O cruzamento é um 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 genética da população, possuindo, assim, uma probabilidade razoável de produzir novos indivíduos mais evoluídos que seus pais.

Esta recombinação é feita tentando imitar, em um alto nível de abstração, a reprodução de genes em células. Trechos das características de um indivíduo são trocados pelo trecho equivalente do outro.

O cruzamento é aplicado com uma dada probabilidade a cada par de cromossomos selecionados. Na prática, esta probabilidade, denominada de taxa de cruzamento, varia entre 60% e 90%[25]. Não ocorrendo o cruzamento, os filhos serão iguais aos pais (isto permite que algumas soluções sejam preservadas).

Existem muitos tipos de cruzamento, entretanto considerando-se a codificação binária[25], serão apresentados a seguir três tipos, que são: cruzamento com um ponto de corte, com dois pontos de cortes e uniforme.

Um Ponto de Corte

Esta é a forma mais simples de implementação do operador de cruzamento, onde dois indivíduos da população, após a seleção, são submetidos ao processo de cruzamento, que se dá da seguinte maneira: o ponto de corte é aleatoriamente gerado, e este é menor ou igual ao tamanho do cromossomo. Depois, os caracteres que precedem o ponto de corte são preservados, e os caracteres posteriores são trocados entre o par (progenitores) participante do processo.

A figura 8 ilustra a operação de cruzamento de um ponto de corte, onde o ponto de corte encontra-se no entre o sétimo e oitavo gene. Em azul temos os genes que serão mantidos, e em verde e amarelo os genes que serão trocados, gerando assim, novos descendentes.

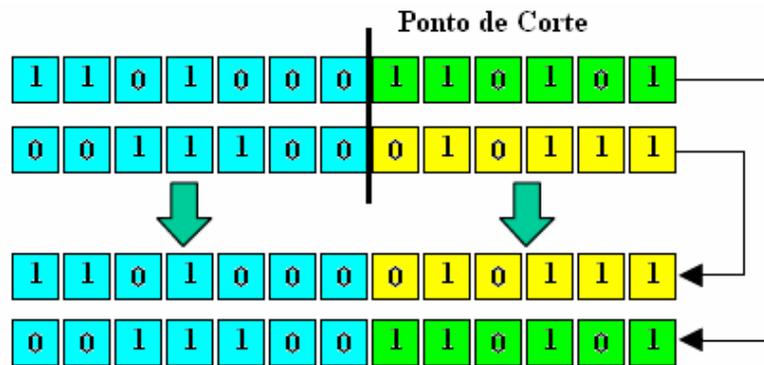


Figura 8. Exemplo de Cruzamento com um ponto de Corte

Dois Pontos de Corte

O procedimento para a operação de cruzamento com dois pontos de corte é similar ao apresentado para de um ponto, com a diferença que neste são selecionados dois pontos de corte e, somente os genes (bits) que estiverem nas extremidades dos cromossomos é que serão trocados entre o par de cromossomos selecionados para participar da operação, ou seja, os bits que ficam entre os dois pontos de corte serão preservados.

A Figura 9 ilustra o cruzamento de dois pontos de corte, apenas as extremidades em verde e amarelo são trocadas, os genes, em azul, que se encontram entre os pontos de corte são mantidos.

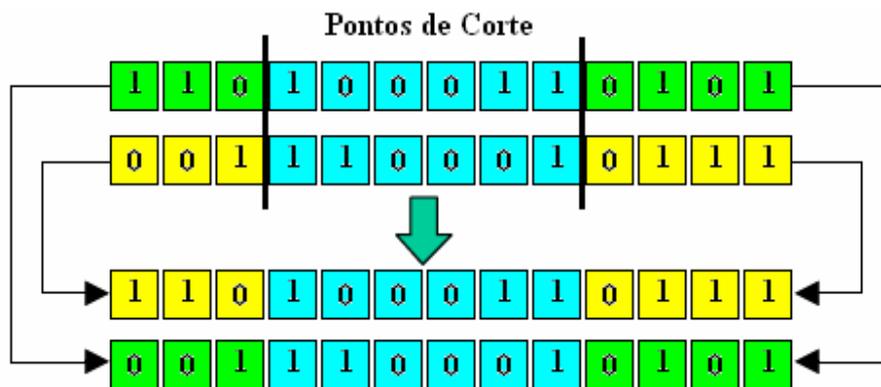


Figura 9. Exemplo de Cruzamento com dois Pontos de Corte

Uniforme

O cruzamento uniforme é radicalmente diferente do cruzamento com um ponto ou dois pontos de corte.

Para cada par de pais é gerada uma máscara de bits aleatórios. Se o primeiro bit da máscara possui o valor 1, então o primeiro bit do *pai1* é copiado para o primeiro bit do *filho1*. Caso contrário, o primeiro bit do *pai2* é copiado para o primeiro bit do *filho1*.

O processo se repete para os bits restantes do *filho1*. Na geração do *filho2* o procedimento é invertido, ou seja, se o bit da máscara é 1, então será copiado o bit do *pai2*. Se o bit for igual a 0, então será copiado o bit do *pai1*.

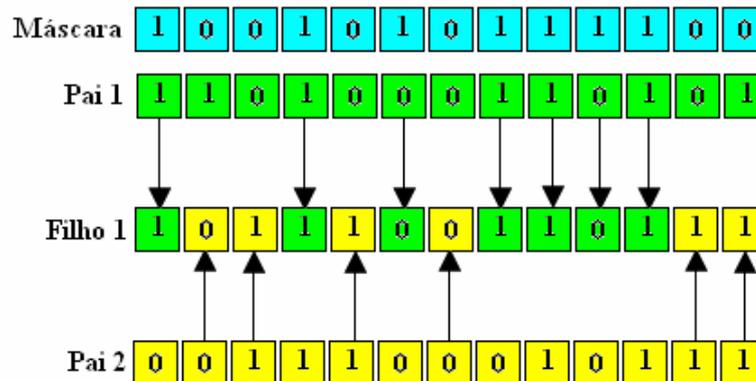


Figura 10. Exemplo de Cruzamento Uniforme

Em Eshelman [15], é investigada a diferença de desempenho entre vários operadores de cruzamento de n pontos e uniforme. A conclusão, conforme relatado em Beasley [6], é que não há diferenças expressivas de desempenho entre eles. Aliás, segundo Grefenstette [19], o AG é robusto de tal modo que, dentro de uma faixa relativamente larga de variação de parâmetros (taxas de cruzamento e mutação, tamanho da população, etc.), não ocorre alteração significativa no desempenho.

2.2.9 Mutação

O operador de mutação inverte os valores de bits, ou seja, muda o valor de um dado bit de 1 para 0 ou de 0 para 1, este operador tem o poder de garantir que todos os cromossomos possíveis sejam alcançados [16].

Cartwright [7], em “The Genetic Algorithm in Science”, disse que o efeito da operação de mutação é duplo. Primeiramente, ela provê um mecanismo onde valores não presentes nos cromossomos da população inicial podem ser gerados. Segundo, ela previne a estagnação da população.

A mutação melhora a diversidade dos cromossomos na população, no entanto, destrói informação contida no cromossomo, logo, deve ser utilizada uma taxa de mutação pequena (normalmente entre 0,1% a 5%), mas suficiente para assegurar a diversidade.

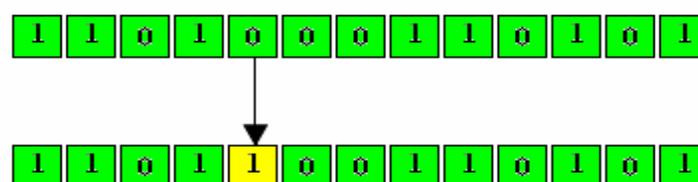


Figura 11. Exemplo de Mutação

Existem algumas diferenças nas definições apresentadas por alguns autores, com relação à operação de mutação. Por exemplo, Goldberg [18], ao decidir aplicar o operador de mutação, o conteúdo do gene (bit, no caso), incondicionalmente, mudará de zero (0) para um (1), e vice-versa. Entretanto, Davis [10], propôs que a alteração desse conteúdo, depende de um gerador de bits aleatório, sendo assim, é possível que não ocorra nenhuma alteração efetiva, e sim, a troca de um bit zero (0) por outro bit zero (0), ou o bit um (1) por outro bit (1), o que não significa dizer que a operação de mutação não tenha ocorrido.

2.2.10 Parâmetros de um Algoritmo Genético

É fundamental que os parâmetros de configuração do AG estejam bem configurados para o bom funcionamento do algoritmo, pois uma má configuração poderia dificultar a busca ou até mesmo levar o algoritmo a uma direção incorreta. Os principais parâmetros utilizados são: tamanho da população, taxa de cruzamento e taxa de mutação.

Tamanho da População

O tamanho da população está relacionado à quantidade de cromossomos que serão permitidos na população em cada geração. Caso seja optado por um valor relativamente pequeno para este parâmetro, ou seja, poucos cromossomos na população, o AG terá poucas opções para realizar as operações de cruzamento e apenas uma parte do espaço de busca será investigado. Em contrapartida, caso essa quantidade seja muito elevada, o AG demorará mais para explorar o espaço de busca, afetando assim o seu desempenho.

A população inicial pode ser gerada de várias maneiras, uma delas é gerar toda população aleatoriamente. Esta forma, dependendo do tamanho da população pode não explorar de forma eficiente todo espaço de busca, levando o AG para uma convergência lenta.

Este problema pode ser minimizado gerando a população inicial de maneira uniforme, isto é, com pontos igualmente espaçados, como se preenchessem uma grade no espaço de busca.

Outra alternativa é gerar a primeira metade da população aleatoriamente e a segunda metade a partir da primeira, invertendo os bits. Isto garante que cada posição da cadeia de bits tenha um representante na população com os valores 0 e 1, como pode ser visto na Tabela 2.

Tabela 2. Geração da População Inicial

1ª Metade (Gerada Aleatoriamente)	2ª Metade (Bits invertidos da 1ª Metade)
1001101011	0110010100
1011101010	0100010101
0010011011	1101100100
0101001000	1010110111

Taxa de Cruzamento

Este parâmetro é responsável pela frequência em que a operação de cruzamento será aplicada. Um valor baixo para este parâmetro resulta num baixo aproveitamento da informação genética existente, tornando lento o processo de convergência para uma solução. Por outro lado, um valor alto poderia resultar numa convergência prematura.

Caso não haja a operação de cruzamento, ou seja, a taxa seja igual a 0%, então todos os descendentes serão uma cópia exata dos pais, o que não garante que a próxima geração seja idêntica a anterior.

Em contra partida, caso a taxa seja igual a 100%, todos os descendentes serão gerados através da operação de cruzamento, sendo compostos por partes dos cromossomos da geração anterior.

O valor habitual para esta taxa é normalmente alto, estando entre cinquenta 50% a oitenta por cento 80%.

Taxa de Mutação

Esta taxa está relacionada à probabilidade de partes dos cromossomos serem alteradas através da operação de mutação.

No algoritmo original de Holland [22], a probabilidade de mutação é aplicada a cada gene de cada indivíduo da população, sob uma probabilidade P_{mut} de ocorrer. A utilização de uma probabilidade baixa resulta em um uso não satisfatório do operador, o que contribui para a estagnação do algoritmo em uma solução local. Porém, uma probabilidade alta implicaria numa busca completamente aleatória.

Conforme Goldberg [18], a operação de mutação atua em segundo plano nos AG, e para ter bons resultados, ela ocorre na ordem de uma mutação a cada mil bits transferidos, estabelecendo assim, um valor de taxa um pouco maior que zero 0% e até dez por cento 10%.

Tamanho do Cromossomo

O Tamanho do Cromossomo está intimamente ligado ao problema abordado e determina o tamanho das soluções candidatas desse problema. Por exemplo, no caso do problema do corte dos lotes da cana-de-açúcar, o tamanho do cromossomo representa a quantidade de lotes de uma usina.

Número máximo de Gerações

Este parâmetro determina a quantidade máxima de gerações que serão produzidas, ou seja, o número de evoluções que o AG deverá atingir antes de terminar a sua execução.

Alguns dos critérios mais utilizados de parada para os AGs, são:

- Quando o AG atingir um dado número de gerações (ou avaliações);
- Chegada ao valor ótimo da função objetivo, se este é conhecido;
- Convergência, isto é, quando não ocorrer melhoramento significativo no cromossomo de maior aptidão por um dado número de gerações.

Outras alternativas são também usadas, por exemplo: considere que um gene converge se 90% da população tem o mesmo valor para este gene. Se entre 90% e 95% dos genes convergiram, o AG convergiu.

Considerações Finais

Muitos autores, propõem o uso de valores padrão para estes parâmetros tradicionais, por exemplo, K. de Jong [23] sugeriu os valores 50, 0.6 e 0.001 para o tamanho da população, taxa de cruzamento e taxa de mutação, respectivamente.

A literatura sobre os AGs discute bastante a definição dos valores para esses parâmetros e, também, uma série de estudos já foi realizada na tentativa de encontrar valores ótimos, ou quase, para os parâmetros, porém não existem trabalhos conclusivos a respeito disso. Na maioria das vezes, os valores definidos são baseados na experiência já adquirida, e em casos já relatados.

2.2.11 Teorema dos Esquemas (Schemata Theorem)

O Teorema dos Esquemas de Holland [22] procura fundamentar, teoricamente, o comportamento dos AGs. Sua compreensão pode auxiliar na construção de aplicações eficientes de AGs.

Holland constatou que os AGs manipulam determinados segmentos da cadeia de bits. Tais segmentos foram por ele denominados de esquemas.

Levando-se em consideração as listas geradas com base em um alfabeto binário $V = \{0,1\}$, representadas utilizando-se letras maiúsculas, e compostas por caracteres individuais representados por letras minúsculas acrescidos de suas respectivas posições, temos um indivíduo I representado por uma lista de sete caracteres, $I = 0111000$ e que é representado simbolicamente por: $I = g_1g_2g_3g_4g_5g_6g_7$.

Cada g_i representa um único gene, isto é, fazendo-se uma analogia com a natureza, que pode assumir os valores 0 ou 1, que são chamados de alelos.

A população de indivíduos é representada por P_j , $j = 1, 2, \dots, n$, onde os indivíduos I_1, I_2, \dots, I_n estão contidos em uma população no tempo t , ou seja, $P(t)$.

O esquema será representado através da letra H , e este será gerado com base no alfabeto $V+ = \{0,1,*\}$, onde o símbolo “*” pode ser utilizado para substituir tanto o “0”, quanto o “1”.

Tabela 3. Exemplo de Esquemas gerados com base no alfabeto $V+ = \{0, 1, *\}$.

	$H_1 = 1****$	$H_2 = **10*$	$H_3 = *0*01$
11001	X		
11011	X		
10101	X	X	X

Comprimento $\delta(H_1) = 0$ Ordem $O(H_1) = 1$

Comprimento $\delta(H_2) = 1$ Ordem $O(H_2) = 2$

Comprimento $\delta(H_3) = 3$ Ordem $O(H_3) = 3$

Conforme mostrado na Tabela 3, os esquemas H_1, H_2 e H_3 estão contidos no mesmo cromossomo 10101, que ao todo pode ter $2^5 = 32$ esquemas. Os cromossomos 11001, 11011 e 10101 possuem o esquema H_1 . O comprimento de um esquema $\delta(H)$ é a diferença entre a última posição 0 ou 1 e a primeira posição 0 ou 1. A ordem $O(H)$ de um esquema é o número de símbolos 1 e 0 que o esquema contém.

Para prever a variação do número de esquemas H entre duas gerações consecutivas, considere “ m ” o número de cromossomos da população atual que contém o esquema H .

Considere “ b ” a média das aptidões de toda população e “ a ” a média das aptidões dos cromossomos que contém o esquema H . Assim, o número esperado de cópias “ m ” do esquema H na população intermediária (utilizando seleção proporcional à aptidão) é dada pela Equação 10:

$$m' = \frac{a}{b} m$$

Equação 10. Número esperado de m' cópias do Esquema H

Pela equação acima, conclui-se que o número de esquemas H aumentará na população intermediária se $a > b$, ou seja, se o esquema H estiver contido em cromossomos de aptidão acima da aptidão média da população (bons cromossomos). No entanto, ao passar para a próxima população, o esquema H pode ser destruído pelos operadores de cruzamento e de mutação.

Por exemplo:

Esquema contido em $pai1 = 01^*|**10$
 Esquema contido em $pai2 = * **|*101$
 Esquema contido em $filho1 = 01^*|*101$

O esquema do $pai2$, que tem pequeno comprimento, foi transmitido ao $filho1$, mas o esquema do $pai1$, que tem maior comprimento, foi destruído pelo cruzamento. Porém, mesmo considerando estes fatores, o Teorema dos Esquemas afirma que:

Pequenos esquemas contidos em bons cromossomos (i.e. aqueles com aptidão acima da média) aumentam exponencialmente nas gerações seguintes, ao passo que esquemas contidos em cromossomos ruins (i.e. aqueles com a aptidão abaixo da média) tendem a desaparecer nas gerações seguintes [18].

Os bons esquemas de pequeno tamanho recebem o nome especial de blocos de construção. A informação contida em um bloco de construção é combinada com as informações de outros blocos de construção. No decorrer das gerações, esta combinação produz cromossomos de alta aptidão. Esta afirmação é conhecida como a Hipótese dos Blocos de Construtores.

2.2.12 Hipótese dos Blocos Construtores (Building Blocks Hypothesis)

De acordo com Goldberg [18], a performance dos Algoritmos Genéticos é compreendida a partir do Teorema dos Esquemas, conforme apresentado. Esquemas curtos, de pequena ordem e com alto valor de aptidão são gerados, recombinados e novamente gerados com o intuito de formar indivíduos com um alto valor de aptidão.

De certa forma, através destes esquemas em particular, foi possível reduzir a complexidade anteriormente existente, e ao invés de construir indivíduos de alta performance através da tentativa de todas as combinações imagináveis, estes são construídos a partir das melhores soluções parciais de gerações anteriores.

Devido ao importante papel realizado pelos esquemas curtos, de pequena ordem e alta adaptabilidade no procedimento executado pelos Algoritmos Genéticos, é que estes passaram a se chamar “Blocos Construtores”.

Os problemas que não obedecem à Hipótese dos Blocos de Construção são conhecidos como AG-Deceptivos, ocorrendo quando combinados dois ótimos blocos de construção, resulte em um cromossomo ruim.

Holland também notou que apesar do AG manipular N cromossomos, a quantidade de esquemas manipulados é muito maior, na ordem de $O(N^2)$ esquemas. Tal propriedade foi denomi-

nada de Paralelismo Implícito. Ou seja, o AG manipula uma grande quantidade de informações em paralelo com apenas N cromossomos.

Sob a luz dos esquemas, é possível analisar os diversos tipos de cruzamentos. Por exemplo, o esquema 1*****0 pode ser fatalmente destruído pelo cruzamento de 1 ponto, seja onde for o ponto de corte. O mesmo problema não ocorre no cruzamento de 2 pontos, porém, o aumento excessivo de pontos de corte normalmente não leva a bons resultados, uma vez que destrói com facilidade os blocos de construção [6][10].

Considerando agora o efeito destrutivo dos blocos de construção causada pelo cruzamento uniforme, Syswerda [35] argumenta que tal destruição é compensada pelo fato dele poder combinar qualquer material dos cromossomos pais, independentemente da ordem dos genes.

Capítulo 3

Metodologia

Neste capítulo o processo de desenvolvimento do protótipo é abordado de forma a apresentar os detalhes relativos à modelagem do problema, projeto e implementação do mesmo.

O protótipo de software desenvolvido neste projeto tem como intuito melhorar o retorno de uma empresa agrícola auxiliando na seleção dos melhores lotes de cana-de-açúcar que atendam um conjunto de critérios específicos. A ferramenta foi desenvolvida utilizando Algoritmos Genéticos Binários.

O desenvolvimento deste protótipo é baseado em cinco pontos principais:

- Codificação do problema;
- Função objetivo que se deseja maximizar ou minimizar;
- Algoritmo Genético;
- Características Técnicas;
- Estudos de Casos.

3.1 Codificação do Problema

No AG proposto, cada indivíduo representa uma provável solução do problema contendo informações sobre quais lotes serão selecionados para colheita.

Cada cromossomo é composto por N genes, onde N é o número de lotes que compõem a unidade agrícola em questão. Cada gene pode assumir valores 0 ou 1, indicando respectivamente lote não-selecionado ou lote selecionado.

A população inicial é composta de 50 indivíduos, valor encontrado experimentalmente, que são gerados obedecendo ao seguinte processo: A primeira metade é gerada de forma aleatória e a segunda metade é gerada invertendo-se os bits de cada indivíduo da primeira metade, garantindo-se dessa forma, que boa parte do espaço de busca da solução seja representada [25].

O algoritmo tem como entrada uma tabela Excel onde se encontra especificado para cada lote da unidade agrícola: o indicador de cada lote, a área; e as estimativas de PCC, TCH e Fibra no dia em que será estabelecido o corte.

3.2 Função Objetivo

O problema de seleção de lotes de cana-de-açúcar para colheita foi expresso pelas seguintes equações. A Equação 11 mostra a função multiobjetivo que se deseja maximizar para a escolha dos lotes de cana-de-açúcar para colheita:

$$h(x, t) = \alpha * c(x) + (1 - \alpha) * f(x) - \beta * \Phi(x, t) - \gamma * \Phi(x)$$

Equação 11. Função Multiobjetivo que se deseja maximizar para decisão de seleção de lotes a cortar

As Funções $c(x)$ e $f(x)$, especificadas nas Equações 12 e 13, determinam respectivamente os valores do PCC total e Fibra total que se pretende maximizar, a fim de maximizar a quantidade de açúcar obtida (produto almejado) e a quantidade de matéria seca após a moagem (combustível para as caldeiras das usinas) dos lotes selecionados para colheita.

$$c(x) = \frac{100 * \sum_{i=1}^N x_i * PCC_i}{\sum_{i=1}^N PCC_i}$$

Equação 12. Função que determina o valor de PCC total

$$f(x) = \frac{100 * \sum_{i=1}^N x_i * Fibra_i}{\sum_{i=1}^N Fibra_i}$$

Equação 13. Função que determina o valor de Fibra total

As funções $c(x)$ e $f(x)$ obedecem a um critério de ponderação α que é fornecido pelo usuário determinando o grau de relevância de cada uma das funções. Este critério de ponderação fornecido fará com que o algoritmo faça uma busca pela melhor solução de acordo com o que o usuário achar mais importante maximizar: PCC ou Fibra.

A função $\Phi(x,t)$ é uma restrição para a tonelagem que se deseja cortar, e é especificada nas Equação 14 e 15.

$$\Phi(x,t) = \frac{100 * | \text{Min}(0, (t - \text{Test})) |}{| t - \sum_1^N \text{Area}_i * \text{TCH}_i |}$$

Equação 14. Restrição para a Tonelagem que se deseja cortar

$$\text{Test} = \sum_1^N x_i * \text{Area}_i * \text{TCH}_i$$

Equação 15. Tonelagem Estimada

$\Phi(x,t)$ corresponde ao mínimo do módulo da diferença entre a tonelagem desejada t (fornecida pelo usuário) e a tonelagem estimada Test , dividido por constante de normalização que corresponde ao máximo do módulo da diferença possível entre as variáveis t e Test . Test é calculada como o somatório das estimativas de tonelagem dos lotes selecionados. Esta função fará com que o algoritmo encontre uma solução com a tonelagem total o mais próximo possível da tonelagem desejada.

A função $\Phi(x)$ é uma restrição quanto o número de lotes selecionados para o corte, veja a Equação 16. Esta função ajuda o algoritmo a cortar um número mínimo de lotes.

$$\Phi(x) = \frac{100 * \sum_1^N x_i}{N}$$

Equação 16. Restrição para o número de lotes a cortar

As funções $c(x)$, $f(x)$, $\Phi(x,t)$, $\Phi(x)$ estão normalizadas para uma escala de 0 a 100.

As variáveis β e γ são constantes de penalização utilizadas para controlar a intensidade da penalidade. Foram utilizadas β igual a 10^{-2} e γ igual a 1. Estes valores foram encontrados experimentalmente em testes preliminares.

3.3 Algoritmos Genéticos

Nesta seção serão apresentados os operadores de Avaliação, Seleção, Cruzamento e Mutação; o critério de parada e a incorporação do Elitismo na implementação do algoritmo genético deste trabalho.

3.3.1 Avaliação da Aptidão

Na avaliação dos indivíduos é utilizado o método de Ordenamento Linear, de modo a garantir que os valores da aptidão não assumam valores muito próximos ou que alguns indivíduos assumam valores muito elevados em relação ao restante da população, incorrendo em problemas já previamente elucidados como busca aleatória e convergência prematura.

3.3.2 Método de Seleção e Operadores Genéticos

A seleção por amostragem estocástica universal é utilizada para determinar os indivíduos mais aptos para gerar novos descendentes na próxima geração.

Logo após a seleção, os indivíduos passam por processos de cruzamento e mutação. Foram utilizados 3 tipos de métodos de cruzamento, permitindo ao usuário selecioná-los livremente:

- Um ponto;
- Dois pontos;
- Uniforme.

Dado que os operadores de cruzamento e mutação são dependentes de probabilidades predefinidas pelo usuário.

Tanto o tipo de cruzamento quanto as probabilidades de cruzamento e mutação foram definidas como padrão: 80% para cruzamento e 3% para mutação. Sendo possível ao usuário retornar a esta configuração padrão. A pressão seleção utilizada foi definida como 0,5.

Estes valores foram definidos como padrão devido ao AG, em testes preliminares, ter apresentado um melhor desempenho, levando o AG a melhores soluções num menor número de gerações.

3.3.3 Critério de Parada

Foram adotados dois tipos possíveis de critérios de parada do AG, os quais também são parâmetros possíveis de serem determinados pelo usuário:

- Número de Gerações: o AG irá evoluir a solução até um determinado número de gerações;
- Convergência do AG: passada a quantidade de gerações, definidas pelo usuário, sem que o melhor indivíduo sofra alguma modificação o AG terá convergido.

3.3.4 Elitismo

Além dos operadores básicos, um esquema de elitismo foi também incorporado ao Algoritmo Genético. A função do elitismo é preservar as melhores soluções encontradas, para que essas não se percam durante o processo de evolução.

Toda a população é substituída em cada geração, ou seja, são criados N filhos para substituir N pais. Os k melhores pais nunca são substituídos por filhos piores, neste AG o valor de k foi definido como 1, aumentando o valor de k , aumenta-se o risco da convergência prematura.

3.4 Características Técnicas

A seguir, serão apresentadas características técnicas utilizadas no desenvolvimento deste trabalho.

3.4.1 Linguagem de Programação

A linguagem escolhida para o desenvolvimento do protótipo foi C#.

O C# é uma linguagem de programação orientada a objetos, na qual os programas são criados usando-se um IDE (*Integrated Development Environment* – Ambiente de Desenvolvimento Integrado), no caso do desenvolvimento deste protótipo o IDE utilizado foi o Microsoft Visual Studio .NET 2003[11].

Com este IDE, pode-se criar, executar, testar e depurar programas em C# convenientemente, reduzindo assim, o tempo que levaria para produzir um programa funcional a uma fração do que levaria sem usar o IDE.

Foi utilizada a biblioteca TeeChart.Lite para .NET da empresa Steema, responsável pela criação e customização de gráficos.

Os diagramas de classes e Casos de Uso foram desenvolvidos utilizando-se a ferramenta JUDE community.

3.4.2 Formato da Entrada

A entrada de dados do protótipo se dá através de uma planilha eletrônica MS-Excel compatível com versões superiores à versão 97.

Esta planilha deve ser padronizada de acordo com os seguintes passos:

1. Abra a planilha Excel com os dados a serem utilizados;
2. A seguir, selecione as linhas e colunas com os dados e no menu: **Inserir** selecione a opção **Nome**, e a seguir **Definir**.
3. Na Janela **Definir Nome** – informe o nome CanaDeAcucar e **OK**.
4. O nome da planilha, *arquivo.xls*, pode ser qualquer um.

A planilha deve obedecer a seguinte estrutura de ordenação de colunas:

- Primeira Coluna: Número do Lote;
- Segunda Coluna: Área de plantio do Lote;
- Terceira Coluna: PCC;
- Quarta Coluna: TCH;
- Quinta Coluna: Fibra;

	A	B	C	D	E
1	Lote	Área(ha)	PCC	TCH	Fibra
2	1	35	12,65035	113,3728	12,5287
3	2	33	12,60168	93,48303	16,28966

Figura 12. Planilha Eletrônica com informações de estimativas de PCC, TCH e Fibra.

Capítulo 4

Desenvolvimento do Protótipo

Este capítulo tem como objetivo apresentar o protótipo de software desenvolvido neste projeto. O protótipo consiste de uma ferramenta de fácil utilização e interface amigável com a capacidade de fornecer aos usuários um suporte a decisão agrícola do corte de lotes de cana-de-açúcar.

4.1 Diagrama de Classes

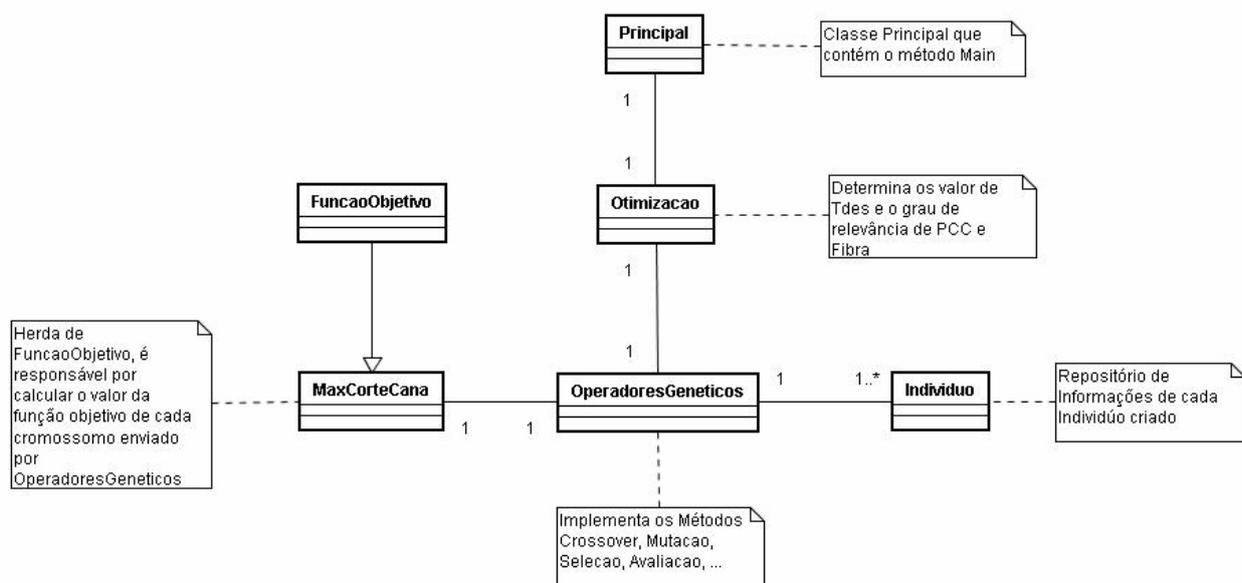


Figura 13. Diagrama de Classes Simplificado do Protótipo de Software Desenvolvido.

A Figura 13 apresenta um diagrama de classes simplificado do protótipo de software desenvolvido neste trabalho, onde não são apresentados os atributos e operações realizadas em cada classe.

A classe Principal contém o método Main, executado quando o programa inicia. É a classe que contém métodos responsáveis pela validação das configurações de parâmetros do AG e validação do arquivo de entrada.

A classe Otimizacao é responsável pela determinação dos valores da tonelagem desejada, grau de relevância do PCC e Fibra e pela execução do AG.

A classe OperadoresGeneticos implementa os métodos: Avaliação da População, Seleção, Cruzamento, Mutação, Elitismo, Ordenamento Linear e outros métodos auxiliares.

A classe Individuo é um repositório de informações de cada cromossomo. Contém informações como: a cadeia de bits que representa cada indivíduo, o valor da função objetivo do cromossomo avaliado e o valor de aptidão gerado pelo ordenamento linear.

A classe FuncaoObjetivo é uma classe abstrata que contém a assinatura dos métodos de avaliação da função objetivo.

A classe MaxCorteCana é uma classe que herda de FuncaoObjetivo e implementa métodos para avaliação da função objetivo para o problema de decisão de seleção de lotes a cortar.

A forma com que este AG foi desenvolvido permite ser utilizado facilmente para resolver outros problemas, bastando somente criar uma classe com a função objetivo desejada herdando da classe FuncaoObjetivo.

4.2 Diagrama de Caso de Uso

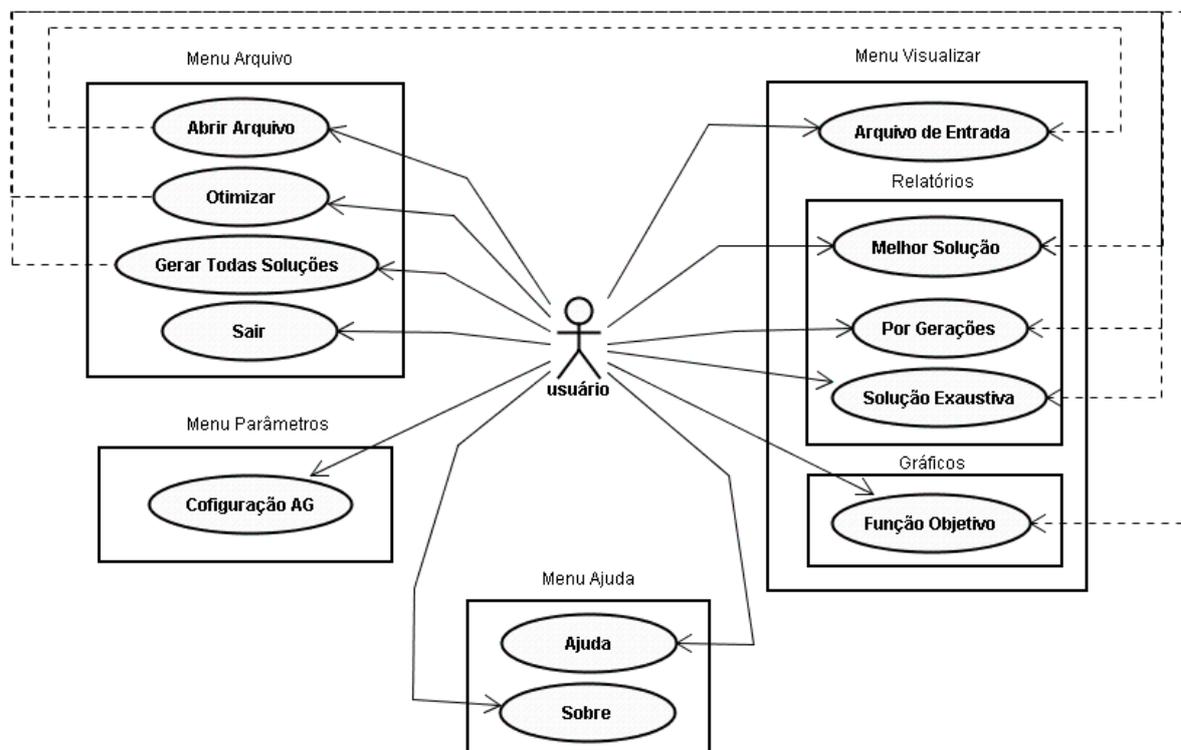


Figura 14. Diagrama de Casos de Uso do Protótipo de Software Desenvolvido.

O diagrama de casos de usos (Figura 14) ilustra todas as funcionalidades da ferramenta e suas dependências entre si. Foi desenvolvido com o intuito de ajudar um gerente agrícola na decisão de seleção de lotes a cortar.

Inicialmente o gerente agrícola não necessita conhecer nenhuma informação sobre AGs, bastando ao gerente somente abrir um arquivo Excel (Menu Arquivo, Abrir) que contenha informações sobre a usina de acordo com as especificações na seção 3.4.2. Indicar os valores da Tonelagem desejada a cortar e do grau de relevância de PCC e Fibra (Menu Arquivo, Otimizar) e verificar a melhor solução encontrada pelo protótipo (Menu Visualizar, Relatórios, Melhor Solução).

A ferramenta oferece a capacidade de gerar todas as soluções possíveis para informações Tonelagem desejada e grau de relevância de PCC e Fibra (Menu Arquivo, Gerar Todas Soluções). Também oferece a possibilidade de configuração dos parâmetros do AG (Menu Parâmetros, Configuração).

Há mais visualizações de informações, como:

- Arquivo de Entrada (Menu Visualizar, Arquivo de Entrada);
- Mais duas visualizações de relatórios:
 - Por Gerações, mostra informações parciais dos resultados encontrados pelo AG a cada iteração.
 - Solução Exaustiva, mostra os resultados obtidos de todas as soluções possíveis para a entrada e parâmetros de Tonelagem Desejada, PCC e Fibra.
- Gráficos, que mostra um gráfico com os melhores e médios valores da Função Objetivo.

E por fim, tem-se o menu Ajuda que fornece informações de como realizar o processamento da planilha Excel para utilização com o protótipo de software desenvolvido neste trabalho (Menu Ajuda, Ajuda) e informações sobre o protótipo, desenvolvedor e orientador (Menu Ajuda, Sobre).

4.3 Interface Gráfica

Nesta seção são especificados os detalhes sobre o desenvolvimento da interface gráfica. A Figura 15 apresenta o formulário principal contendo as opções de menu.

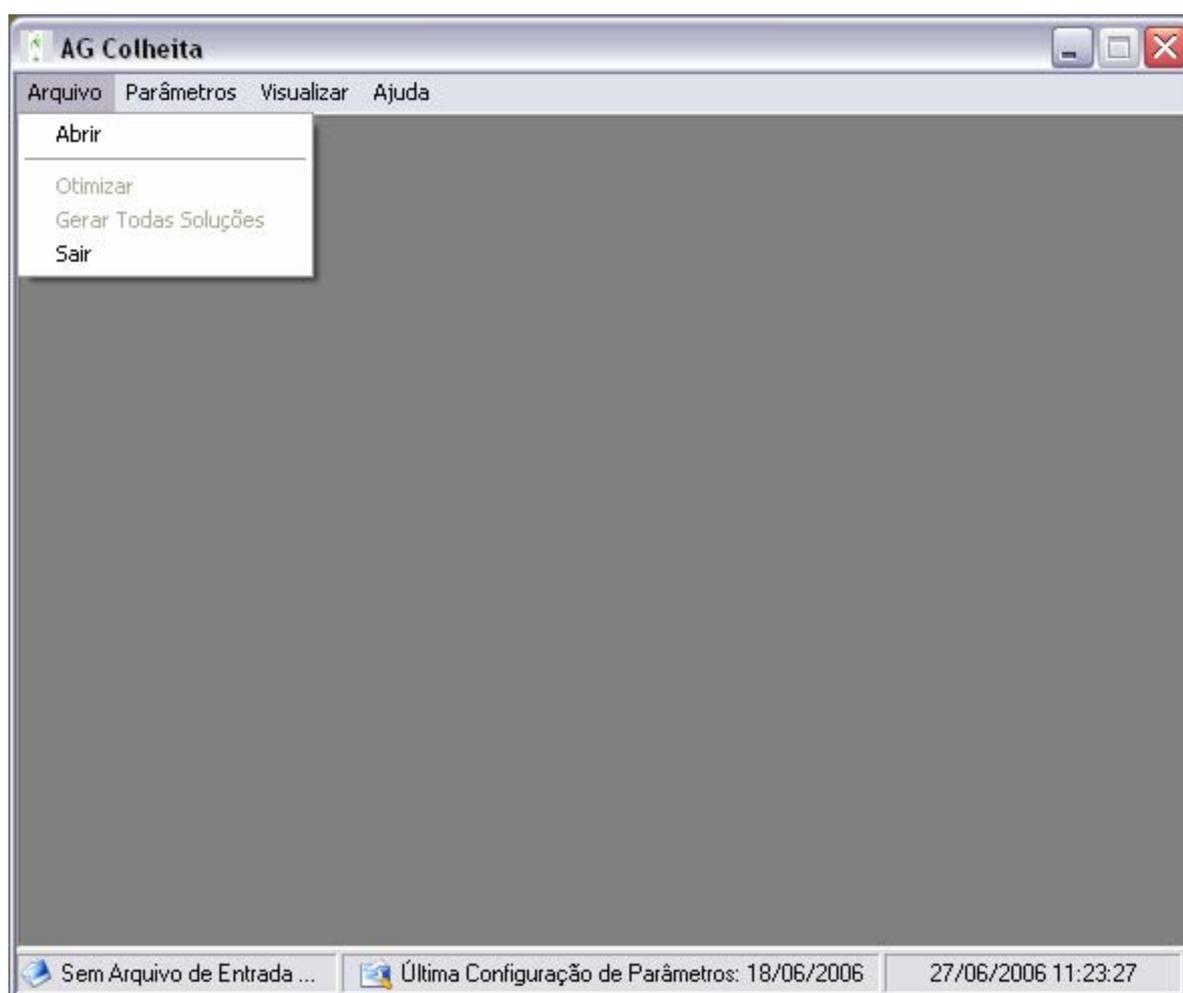


Figura 15. Interface Principal do Protótipo de Software Desenvolvido.

4.3.1 Menu Arquivo

O menu arquivo dá acesso a quatro funcionalidades básicas:

- **Abrir:** Ao clicar nesta opção uma janela solicitando para selecionar o arquivo de entrada será exibida. Após selecionar o arquivo a opção *Otimizar* será habilitada.

- Otimizar: Executa o AG conforme a configuração de parâmetros e atribuições da função objetivo e restrições, como apresentado na Figura 16.
 - Permite selecionar quais funções deseja-se maximizar (PCC e/ou Fibra) e atribuir um grau de relevância a cada uma;
 - Permite atribuir um valor a Tonelagem desejada;
- Gerar Todas Soluções: Gera de forma exaustiva todas as soluções possíveis e as ordena em relação a função objetivo.
- Sair: Fecha o programa.

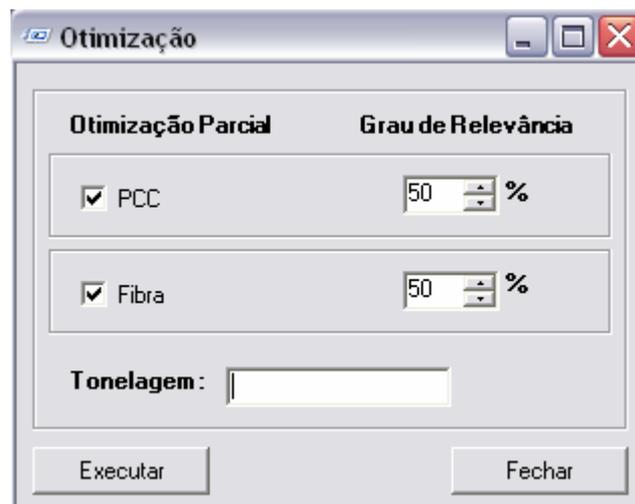


Figura 16. Menu Otimização do Protótipo de Software Desenvolvido.

4.3.2 Menu Parâmetros

O menu parâmetros tem somente uma opção: Configurar AG.

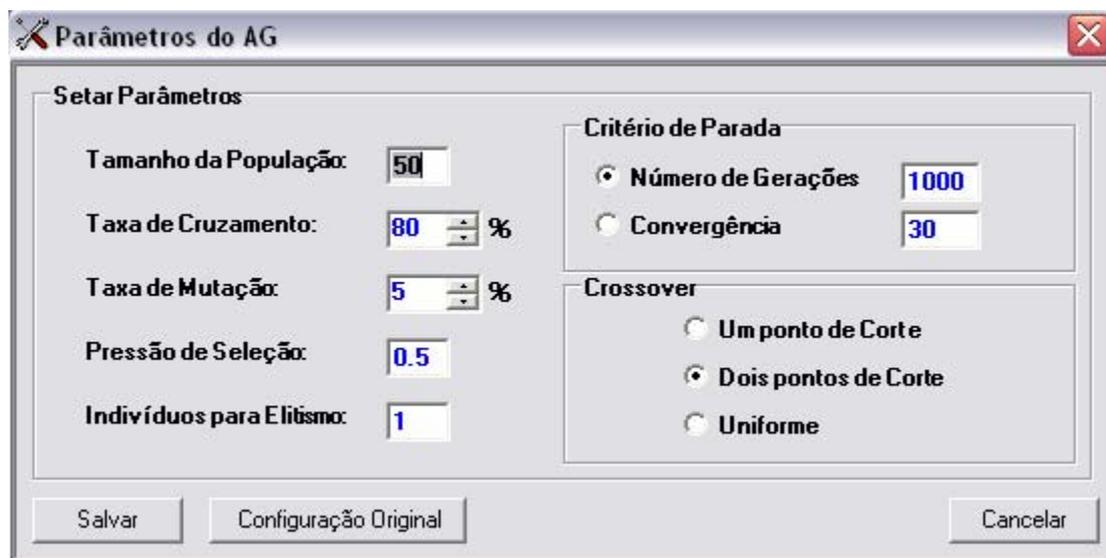


Figura 17. Menu Parâmetros do Protótipo de Software Desenvolvido.

Através dessa opção (Figura 17) é possível definir:

- O tamanho da população de indivíduos;
- A taxa de cruzamento, assim como o tipo de cruzamento a se utilizar dentre: um ponto, dois pontos e uniforme;
- A taxa de mutação;
- A pressão de seleção;
- O número de indivíduos para elitismo;
- O critério de parada: número de gerações ou convergência do AG.

Há também um botão que faz com que os parâmetros do AG voltem à configuração padrão estabelecido neste trabalho

4.3.3 Menu Visualizar

Esse menu dá acesso a três funcionalidades:

- Arquivo de entrada: Exibe uma janela com os dados do arquivo de entrada;
- Relatório: Exibe dois tipos de relatórios
 - Melhor solução (Figura 18);
 - Por geração.
- Gráfico:
 - Função Objetivo (Figura 19): Exibe o gráfico com informações dos melhores resultados e valores médios da função objetivo em cada geração.



Figura 18. Visualizar Relatório: Melhor Solução

No relatório, Melhor Opção (Figura 18), é possível se observar :

- O cromossomo que representa o Melhor indivíduo, ou seja, a melhor solução encontrada pelo AG;
- O PCC, Fibra e Tonelagem totais dos lotes a cortar;
- O identificador de cada lote a cortar da melhor solução encontrada.

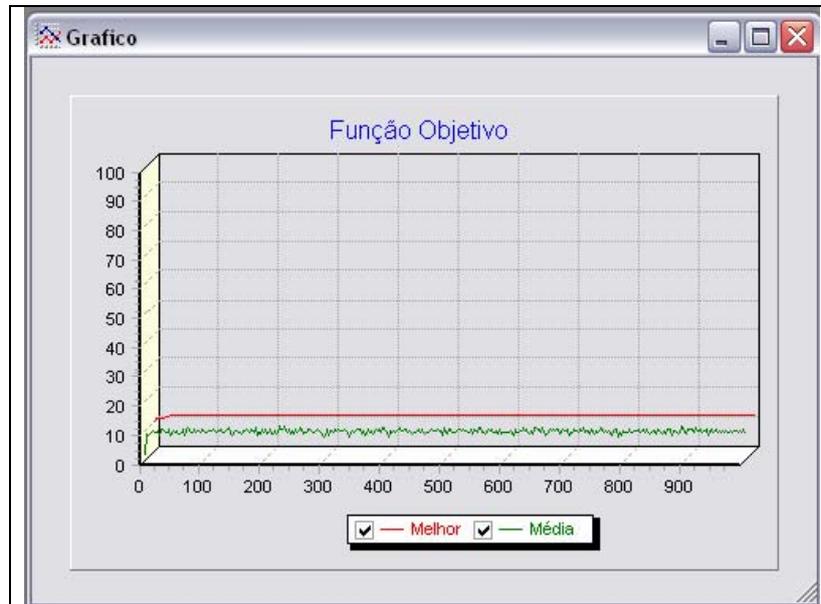


Figura 19. Visualizar Gráfico: Função Objetivo

O gráfico gerado (Figura 19) mostra os melhores valores da função objetivo, em vermelho, e os valores médios da função objetivo, em verde, em cada população para cada geração do AG.

4.3.4 Menu Ajuda

O menu ajuda tem duas opções:

- Ajuda (Figura 20) – Exibe um tutorial ensinando como formatar a entrada de dados;

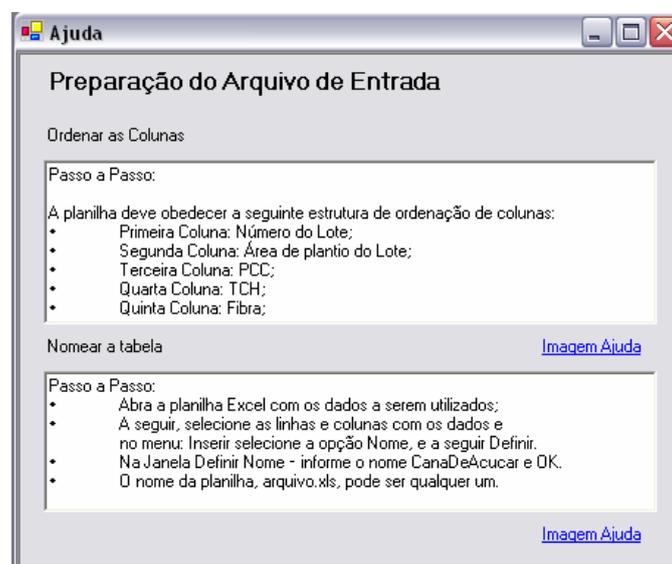


Figura 20. Menu Ajuda: Ajuda

- Sobre (Figura 21) – Exibe uma janela contendo uma descrição resumida do protótipo, informações sobre o autor e sobre o orientador do projeto.



Figura 21. Menu Ajuda: Sobre

Capítulo 5

Resultados Experimentais

Esta seção descreve três testes efetuados com o protótipo de software desenvolvido neste projeto.

5.1 Arquivo de Entrada

Foram utilizadas como entradas duas planilhas Excel: uma com dados sobre 15 lotes (Cana15) e outra com dados sobre 380 lotes (Cana380) como especificados na seção 3.5. As soluções encontradas pelo AG, dada à planilha e critérios e restrições estabelecidos, foram comparadas com as melhores soluções previamente conhecidas geradas de forma exaustiva.

Neste presente trabalho, as planilhas contêm estimativas de PCC, TCH e Fibra, para um conjunto de lotes candidatos, advindas de uma rede neural treinada com dados de produção de safras anteriores de uma usina de açúcar situada no noroeste do estado de São Paulo [29].

5.2 Estudos de Casos

Nesta seção serão apresentados dois estudos de casos realizados com duas planilhas que correspondem respectivamente a unidades agrícolas com 15 e 380 lotes.

Neste presente trabalho, as planilhas contêm estimativas de PCC, TCH e Fibra, para um conjunto de lotes candidatos, advindas de uma rede neural treinada com dados de produção de safras anteriores de uma usina de açúcar situada no noroeste do estado de São Paulo [29].

5.2.1 Cana15

Este caso consiste de uma planilha Excel (Apêndice A, Tabela 9), com 15 lotes. Este caso foi elaborado como exemplo na dissertação de Mestrado de Fernando Buarque [29] a qual se refere a informações de safras passadas de uma usina de cana-de-açúcar do estado de São Paulo.

Tabela 4. Média Aritmética e Desvio Padrão para PCC, TCH e FIBRA da Tabela 9

	ÁREA	PCC	TCH	FIBRA
Média	28,13333	13,89011331	85,81040383	15,58510823
Desvio Padrão	10,49399	1,042512095	13,51506663	1,464916864

Em relação à Tabela 4, tanto para PCC quanto para a Fibra não há uma dispersão muito alta de seus valores para cada lote em relação às suas médias. O mesmo comportamento não ocorre com a Área e o TCH, o quais possuem uma maior variabilidade entre seus valores para cada lote.

Inicialmente, foi utilizado um caso com poucos lotes devido a facilidade em encontrar as soluções ótimas por busca exaustiva e comparar com as obtidas pelo AG afim de testar e encontrar um conjunto de valores para os parâmetros do AG que permitissem ao mesmo encontrar as soluções ótimas.

5.2.2 Cana380

Este caso consiste de uma planilha Excel (Apêndice A, Tabela 10), com 380 lotes a qual contém informações geradas e disponibilizadas através do projeto Intelicolheita [30][36].

Tabela 5. Média Aritmética e Desvio Padrão para PCC, TCH e FIBRA da Tabela 10

	ÁREA	PCC	TCH	FIBRA
Média	10,24682	14,92106819	82,56177789	13,9803874
Desvio Padrão	1,054138	1,054138288	31,4283291	1,73363073

Na Tabela 5 há uma pequena diminuição das médias de TCH e Fibra, um grande diminuição em relação a Área e um pequeno aumento da média do PCC em relação à Tabela 4.

No entanto, a variabilidade dos valores de PCC e Fibra nos lotes da Tabela 5 são relativamente equivalentes ao dos lotes da Tabela 4. Entretanto, em relação ao TCH e Área da Tabela 5, há um aumento da dispersão do TCH e uma diminuição expressiva da variabilidade da Área entre seus valores para cada lote.

Neste caso foi utilizada uma planilha com 380 lotes para se observar o comportamento do algoritmo genético num ambiente mais próximo da modelagem do problema para uma usina.

5.3 Resultados

São apresentados a seguir, a especificação e os resultados de três testes realizados para testar o software desenvolvido.

A entrada do software foi uma das duas planilhas especificadas: Cana15 ou Cana380, e um dos cenários de teste especificados na Tabela 6. A Tabela 6 exibe as informações sobre a Tonelagem desejada, e as ponderações de PCC e Fibra para cada teste.

Tabela 6. Tabela com dados dos testes realizados

Teste	Tonelagem Desejada	Ponderação PCC	Ponderação Fibra
1	2000	50%	50%
2	4800	30%	70%
3	9000	0	100%

Em cada teste os parâmetros do AG utilizados foram os valores padrão especificados anteriormente no capítulo 3. A solução final obtida pelo AG (melhor indivíduo da última geração), foi comparada com as melhores soluções conhecidas para cada planilha sobre o conjunto de critérios e restrições determinados em cada cenário de teste.

A Tabela 7 mostra a melhor solução obtida pelo AG para a planilha Cana15 e os respectivos cenários de teste.

Tabela 7. Melhores soluções para os testes com a planilha Cana15.

Teste	Tonelagem	PCC Total	Fibra Total	Lotes a Cortar
1	2036,45	28,41	32,07	10, 14
2	4756,67	55,29	65,64	4, 6, 10, 14
3	9052,05	85,75	96,66	4, 6, 10, 11, 14, 15

As soluções mostradas na Tabela 7 são as soluções ótimas para a planilha Cana15 e os respectivos cenários estabelecidos. A maioria das execuções dos AGs convergiram para estas soluções em menos de 300 gerações, sendo a convergência para outras soluções mínimos locais pouco provável (1 a cada 10 execuções).

A Tabela 8 mostra a melhor solução obtida pelo AG para a planilha Cana380 e os respectivos cenários de teste.

Tabela 8. Melhores soluções para os testes com a planilha Cana380.

Teste	Tonelagem	PCC Total	Fibra Total	Lotes a Cortar
1	2038,20	45,70	45,09	193, 211, 328
2	4630,60	232,31	241,32	112, 116, 131, 154, 158, 166, 233, 242, 270, 277, 279, 310, 325, 336, 341, 342
3	9035,70	380,80	378,24	57, 77, 92, 94, 112, 132, 150, 151, 165, 187, 202, 207 213, 214, 227, 235, 244, 248, 261, 290, 297, 298, 301, 336 340, 341

Com a planilha Cana380, as soluções obtidas não são ótimas, consistindo de mínimos locais que apenas representam boas soluções. Não foi verificada nenhuma tendência de convergência do AG a nenhuma solução em múltiplas execuções de cada teste. Este fato se explica pela grande quantidade de mínimos locais presentes e a dificuldade da presente configuração do AG em convergir para os mínimos globais.

Capítulo 6

Conclusões e Trabalhos Futuros

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 se tomar. Esta decisão deve levar em consideração um conjunto de critérios relacionados a esta prática agrônômica, como também outros aspectos: como industriais, com o intuito de reduzir custos operacionais e de demandas energéticas.

A definição da melhor época para o corte da cana de cada lote, isto é do momento de acúmulo máximo de açúcares é de grande importância econômica, pois definida esta época evitam-se perdas na produtividade na colheita, visto que, após a melhor época de colheita a cana-de-açúcar irá utilizar suas reservas energéticas (açúcares) para o processo de reprodução.

Com o emprego de algoritmos genéticos no suporte à decisão da colheita da cana espera-se uma efetiva melhoria na atividade agrícola em questão decorrente de um auxílio mais efetivo do sistema nas decisões de colheitas.

Para isso foi desenvolvido um protótipo de software que utiliza AGs e experimentados vários valores de parâmetros do AG. Os valores para os quais o AG obteve os melhores resultados Padronizado para ser executado com uma população de 50 cromossomos, com taxa de cruzamento de 80%, taxa de mutação de 3% e pressão de seleção 0,5, elitismo 1. A variação desses parâmetros resulta em pequenas oscilações no desempenho do AG.

Foram realizados experimentos com duas tabelas que continham informação sobre uma unidade agrícola com 15 lotes e outra com 380 lotes.

Foi possível se observar que para um número pequeno de lotes o AG convergia para as melhores soluções em poucas iterações (300) em um intervalo de tempo pequeno, aproximadamente 10 min. Para um número grande lotes o algoritmo não conseguiu convergir para as melho-

res soluções mesmo com um número mais elevado de iterações (10000) devido a muitos máximos locais.

Vale a pena ressaltar que mesmo para um número relativamente pequeno de lotes, como 15, o número de combinações possíveis para escolha da melhor solução é de $2^{15} = 32768$ possibilidades de solução, o que valida o uso de AGs para resolução deste problema de seleção de lotes a cortar.

Com a utilização do protótipo desenvolvido é possível vislumbrar uma melhora no processo de decisão do corte de lotes de cana-de-açúcar, expresso nos valores máximos de PCC e Fibra, dado um valor de Tonelagem desejado, encontrados pelo protótipo, aumentado dessa forma o retorno da produção agrícola.

O presente trabalho apresenta de forma pioneira uma solução do problema de decisão de seleção de lotes de cana-de-açúcar a cortar utilizando algoritmos genéticos, não tendo conhecimento de trabalhos publicados que tratam do mesmo problema. Um artigo contendo um resumo desta monografia foi submetido para o *I Workshop on Computational Intelligence (WCI)* [1].

Como indicações para estudos e pesquisas futuras, segue uma lista de sugestões:

- Incorporação de outras variáveis ou fatores que influenciem na produtividade ou retorno econômico da cultura, como por exemplo, a distância entre lotes a cortar – O que implicaria numa escolha dos melhores lotes mais próximos evitando-se maiores gastos com combustível para transportes e mão-de-obra;
- Comparar os resultados obtidos neste trabalho com os obtidos utilizando uma abordagem sugerida por Pacheco[31]. Esta comparação não foi possível ser realizada neste presente trabalho devido ao desenvolvimento em paralelo dos dois trabalhos, e a defesa do trabalho de Pacheco ter sido posterior a deste trabalho.
- Validação do sistema por gerentes de uma usina – Para que haja uma melhor avaliação do protótipo e possíveis sugestões de melhorias.
- Testes com outras culturas;

- Uso de algoritmos híbridos que mesclam AGs com outros métodos de otimização, como Simulated Annealing ou Subida de Encosta a fim de diminuir o custo computacional e permitir a obtenção de soluções mais refinadas e próximas das soluções ótimas, principalmente em unidades agrícolas com centenas de lotes;

Bibliografia

- [1] ALENCAR, C.E.R.; CORRÊA, R.F.; NETO, F.B.L., *Ferramenta para suporte à decisão de frentes de corte de cana-de-açúcar usando algoritmos genéticos*. Submetido ao I Workshop on Computational Intelligence (WIC). Ribeirão Preto, 2006.
- [2] BÄCK, T. *An overview of evolutionary algorithms for parameter optimization*. Evolutionary Computation, [S.l.], v.1, n.1, p.1–23, 1993.
- [3] BAKER, J. *Reducing bias and inefficiency in the selection algorithm*. In: GREFFENSTETTE, J. ed., *Proc. of the Second International Conference on Genetic Algorithms and Their Applications*, p.14- 21. Hillsdale, New Jersey: Lawrence Erlbaum Associates, 1987.
- [4] BANZHAF, W; NORDIN, P.; KELLER, R. E. & FRANCONI, F. D. *Genetic Programming: an introduction*. ISBN 155860510X. Morgan Kaufmann, 1998.
- [5] BARBIERI, V; VILLA NOVA, N. A. *Climatologia e Cana de Açúcar*. Araras: PLANALSUCAR – Coordenadoria Regional Sul – Cosul. Climatologia, 1977.
- [6] BEASLEY, D.; BULL, D. R.; MARTIN, R. R.; *An Overview of Genetic Algorithms: Part 1, Fundamentals. Part 2, Research Topics*. University Computing, 1993.
- [7] CARTWRIGHT, H. M. *The Genetic Algorithm in Science*. Physical and Theoretical Chemistry Laboratory, Oxford University, UK, 1996 . Acessado em 9 de maio de 2006: (<http://www.citesser.ist.psu.edu/79259.html>) the-genetic-algorithm-in.pdf.
- [8] CASTRO, P. R. C. *Maturadores Químicos em cana-de-açúcar*. In: Semana da Cana-de-açúcar de Piracicaba, 4. Piracicaba 1999.
- [9] DARWIN, C. *A origem das espécies e a seleção natural*”, Hemus editora, 1994 p. 496.
- [10] DAVIS, L. *Handbook of Genetic Algorithms*. Van Nostrand Reinhold, New York, 1991.
- [11] DEITEL, H. M. *C# Como Programar*. Tradução João Eduardo Nóbrega Tortello; revisão técnica Álvaro Antunes. São Paulo, Editora Pearson Education, 2003.
- [12] EMBRAPA INFORMÁTICA AGROPECUÁRIA. *Experimento em cana-de-açúcar* (<http://www.cnptia.embrapa.br/projetos/ipi/ipi/homepage/cana.html>). Acessado em 21 de Abril de 2006.
- [13] EMBRAPA. *Impacto Ambiental das Atividades Agrícolas*. (<http://www.cana.cnpm.embrapa.br/>). Acessado em 24 de Abril de 2006.
- [14] ENCORE. *The Evolutionary Computation Repository Network* (<http://alife.santafe.edu/~joke/encore/>). Acessado em outubro de 2005.
- [15] ESHELMAN, L. J.; Shaffer, D. J.; *Real-coded genetic algorithms and interval-schemata*. In: WHITLEY, D. L. (ed). *Foundations of Genetic Algorithms 3*. San Mateo, CA: Morgan Kaufman, p.187- 203, 1992.
- [16] FANG, H. L. *Genetic Algorithms in Timetabling and Scheduling*.. PhD Thesis. Department of Artificial Intelligence. University of Edinburgh, 1994.
- [17] FOGEL, L. J.; OWENS, A. J. *Artificial Intelligence Through Simulated Evolution*. John Wiley, 1966.

- [18] GOLDBERG, D. E. *Genetic algorithms in search, optimization and machine learning*. Addison Wesley, 1989.
- [19] GREFENSTETTE, J.J.; *Optimization of control parameters for genetic algorithms*. IEEE trans SMC. v16, p.122- 128.
- [20] HINTERDING, R. *Representation, Mutation and Crossover Issues in Evolutionary Computation*. In: Proc. Conference on Evolutionary Computation, pp 916-923, 2000.
- [21] HOLLAND, J. H. *Outline for logical theory of adaptive systems*. Journal of the ACM, [S.I.], v.3, p.297–314, 1962.
- [22] HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor: The University of Michigan Press, 1975.
- [23] JONG, K. D. *An Analysis of the Behavior of a Class of Genetic Adaptive Systems*. University of Michigan, 1975. Tese de Doutorado.
- [24] KOZA, J. R. *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. ISBN 0262111705. MIT Press, 1992.
- [25] LACERDA, E.G.M, CARVALHO, A.C.P.L. *Introdução aos algoritmos genéticos*. In: Galvão, C.O., Valença, M.J.S. (orgs.) *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*. Porto Alegre: Ed. Universidade/UFRGS : Associação Brasileira de Recursos Hídricos. p. 87-150. 1999.
- [26] MACHADO, E. C. *Fisiologia da Produção da cana-de-açúcar*. Crescimento. In: PARANHOS, S. B. *Cana-de-açúcar: cultivo e utilização*. Campinas: Fundação Cargill, 1987.
- [27] MICHALEWICZ, Z. *Genetic Algorithms + Data Structures = Evolution Programs*. 3.ed. Springer-Verlag, 1994.
- [28] MITCHELL, M. *An Introduction to Genetic Algorithms*. MIT Press, 1999
- [29] NETO, F. B. de L. *Suporte a Decisão Gerencial Baseado em Redes Neurais Artificiais – nDSS*. Dissertação de Mestrado apresentada ao Departamento de Informática da Universidade Federal de Pernambuco Recife, PE, Brasil, 1998.
- [30] PACHECO, D. F. ; REGUEIRA, F. S. ; NETO F. B. de L. ALCOOLbrás. *Utilização de Redes Neurais Artificiais em Colheitas de Cana-de-açúcar para Predição de PCC, TCH e Fibra*, São Paulo - Brasil, v. 90, p. 60 - 63, 01 mar. 2005.
- [31] PACHECO, D. F. *Ferramenta de Apoio a Decisão de Frentes de Cortes usando Redes Neurais*. Monografia de trabalho de conclusão de curso. Universidade de Pernambuco, Recife, 2006.
- [32] RECHENBERG, I. *Evolutionsstrategie: Optimierung Technischer Systeme Nach Prinzipien der Biologischen Evolution*. Stuttgart:Frommann-Holzboog, 1973.
- [33] RUSSEL, STUART J.; NORVING, PETER. *Inteligência Artificial* (2004) 2ª Edição Editora Campus.
- [34] SCHWEFEL, H. P. *Kybernetische Evolution Als Strategie der Experimentellen Forschung inder Strömungstechnik*. Berlin:Technical University of Berlin, 1965. Tese de Doutorado.
- [35] SYSWERDA, G.; Uniform crossover in genetic algorithms. In: J. D. Schaffer, ed. *Proceedings of the Third International Conference on Genetic Algorithms*, p.2- 9. Morgan Kaufmann, 1989.
- [36] TRIGO, Thiago Ramos ; BATISTA JÚNIOR, Paulo César ; BUARQUE DE LIMA NETO, F. . *Redes Neurais Artificiais em Colheita de Cana-de-Açúcar*. In: V Congresso Brasileiro de Agroinformática, 2005, Londrina. Agronegócio, Tecnologia e Inovação. Londrina : Universidade Estadual de Londrina, 2005.
- [37] TANOMARU, J. *Motivação, fundamentos e aplicações de algoritmos genéticos*. In: III Congresso Brasileiro de Redes Neurais e III Escola de Redes Neurais, 1995. Curitiba:[s.n.], 1995.

- [38] YAMADA, M. C. *Modelagem das cadeias de atividades produtivas da indústria sucroalcooleira visando à aplicação em estudos de simulação*. 1999. Dissertação (Mestrado em Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

Apêndice A

Anexo

Tabela 9. Cana15

Lote	Área(ha)	PCC	TCH	Fibra
1	35	12,65035	113,3728	12,5287
2	33	12,60168	93,48303	16,28966
3	34	15,30017	85,64792	15,56353
4	24	14,03548	58,865	18,31322
5	44	14,35194	88,42609	15,77891
6	15	12,84694	87,1641	15,25948
7	34	13,59935	87,9835	15,49224
8	43	13,5961	71,98433	17,29352
9	17	12,73662	92,25992	14,66953
10	12	14,44317	91,71265	14,36881
11	34	15,32613	74,1644	15,60824
12	34	15,16294	82,98039	13,88719
13	30	12,59958	98,90481	15,61156
14	14	13,96753	66,84964	17,69721
15	19	15,13373	93,35743	15,41483

Tabela 10. Cana380

Lote	Área	PCC	TCH	Fibra
1	8,98	16,34905	103,7652	12,63086
2	8,19	15,81817	88,0432	11,02924
3	11,07	14,30935	82,6528	15,23952
4	7,23	15,45319	89,3908	12,88097
5	15,37	15,75705	75,0164	12,67913
6	3,71	14,58876	117,2412	16,18075
7	5,06	16,13774	55,2516	12,09991
8	9,37	15,81991	66,0324	13,92093
9	6,16	16,16394	70,5244	13,89021
10	10,94	15,3746	76,8132	13,44922
11	4,32	16,54464	61,5404	11,95072
12	6,56	15,86706	82,2036	12,52993
13	6,03	16,1587	84,4496	13,38998
14	16,98	14,46651	65,5832	13,6401
15	11,69	15,09694	81,7544	12,87
16	8,78	15,00264	94,7812	12,17012
17	14,2	14,1906	66,0324	13,28906
18	15,45	14,48398	58,396	13,56989
19	19,28	14,25521	60,1928	15,41943
20	19,16	14,30061	66,4816	13,67959
21	13,03	14,46826	58,8452	14,23906
22	17,65	14,13122	53,4548	12,31931
23	18,89	14,38444	52,1072	13,80026
24	10,41	14,45778	61,9896	15,09911
25	7,62	14,72148	75,0164	11,25083
26	5,85	15,05153	64,6848	12,02093
27	9,25	15,02883	109,1556	11,14991
28	14,33	14,58352	93,8828	11,79056
29	7,94	14,56256	79,5084	12,18109
30	9,08	14,53637	93,8828	12,15037
31	7,27	14,89436	106,4604	11,77081
32	10,1	14,17837	154,0756	11,68086
33	7,01	14,05438	132,9632	12,22058
34	6,88	14,2133	154,0756	12,11966
35	10,38	14,16091	150,9312	11,0797
36	7,88	14,96946	68,2784	15,07059
37	16,09	15,47938	69,626	12,94021
38	11,12	15,51431	53,0056	13,71908
39	5,76	15,83563	42,674	12,60892
40	10,72	15,13885	82,6528	13,58964
41	16,8	15,35888	72,7704	13,1991
42	16,64	15,78673	67,8292	12,7603
43	16,09	15,53701	72,7704	12,99945
44	11,06	15,31173	89,84	13,94945

Lote	Área	PCC	TCH	Fibra
45	3,48	15,01835	57,0484	13,94945
46	12,57	15,38159	75,9148	13,38998
47	5,48	14,77387	81,3052	14,62959
48	20,04	15,44795	70,0752	12,6506
49	19,8	15,78848	71,872	12,1394
50	15,82	15,21918	87,1448	13,55892
51	2,49	14,97295	127,5728	13,12012
52	20,46	14,5224	68,7276	15,27902
53	18,54	15,00264	69,626	14,98063
54	14,2	14,89436	64,2356	15,77047
55	16,94	14,97295	73,6688	15,30096
56	13,55	16,75594	69,1768	13,65984
57	4,07	16,26348	169,7976	14,3707
58	6,47	16,50622	85,348	12,49044
59	2,94	16,2076	84,0004	13,65107
60	7,55	16,80833	101,07	12,9797
61	9,3	16,22157	64,2356	12,99067
62	15,21	16,58655	137,9044	12,76908
63	12,81	16,17442	111,8508	13,01042
64	4,19	17,4632	52,5564	15,36019
65	12,38	16,48351	145,0916	12,60014
66	16,85	13,56367	78,61	16,47913
67	14,33	12,99961	75,0164	16,27948
68	9,08	12,87562	102,8668	15,55985
69	11,26	14,80355	73,6688	12,74933
70	13,7	14,69354	74,118	12,49044
71	0,54	13,38729	136,1076	13,40095
72	9,54	14,50843	91,6368	13,96042
73	17,58	14,92405	89,84	14,23906
74	11,17	15,4008	58,396	12,54968
75	12,25	15,33967	75,9148	12,76908
76	12,27	15,29427	51,2088	14,62082
77	2,48	13,51128	97,4764	12,20083
78	7,08	14,29188	103,316	12,74933
79	18,43	14,26394	97,0272	13,49968
80	10,02	12,8599	44,4708	17,72971
81	11,1	15,64179	113,6476	14,55938
82	13,96	15,10567	74,118	12,74056
83	14,91	15,66274	84,0004	14,07012
84	9,65	16,35079	68,7276	13,17936
85	11,9	15,61734	75,4656	15,30973
86	17,09	15,48462	68,2784	15,46989
87	13,8	15,67671	76,8132	14,84022
88	5,77	15,28903	59,7436	14,96089

Lote	Área	PCC	TCH	Fibra
89	9,34	13,18995	104,2144	14,82925
90	16,88	13,39777	94,332	13,90996
91	7,19	13,01183	97,0272	14,05915
92	9,73	13,15154	84,8988	15,59934
93	21,35	13,64051	92,086	14,53086
94	4,02	13,01358	104,2144	15,07059
95	14,44	12,76036	97,4764	14,33998
96	20,28	13,14455	93,4336	13,65984
97	13,67	13,54446	103,316	14,80072
98	17,81	13,48683	91,1876	14,66908
99	20,46	13,85006	97,0272	13,0192
100	15,73	13,73306	98,824	12,4707
101	20,69	13,29648	90,7384	13,08063
102	19,55	13,27203	92,9844	13,40095
103	18,97	14,03867	105,1128	13,33952
104	4,24	13,15852	101,5192	13,78051
105	5,97	13,25282	88,4924	12,83929
106	8,4	13,91992	29,198	17,53006
107	18,8	14,27093	41,3264	19,73064
108	7,99	12,07406	39,5296	21,94
109	6,45	14,01596	45,8184	18,74992
110	20,54	13,97405	39,5296	15,14079
111	12,03	13,47461	36,8344	17,53006
112	3,39	13,1201	28,7488	19,25016
113	9,18	13,60558	25,6044	17,47082
114	5,93	12,55953	51,2088	16,97059
115	13,94	13,40301	38,6312	19,84034
116	5,94	14,22727	35,0376	19,34011
117	9,5	15,51955	83,102	13,73005
118	20,17	15,27506	71,4228	13,69056
119	11,18	15,11789	103,316	13,87924
120	6,58	16,48526	60,642	15,211
121	16,83	15,99978	69,1768	12,85903
122	5,51	14,83324	121,284	11,68086
123	5,67	15,5632	110,5032	12,60014
124	10,53	15,55447	93,4336	13,53917
125	10,91	16,21633	103,316	12,42023
126	17,84	15,97534	96,1288	12,52993
127	14,11	15,66449	91,6368	13,74102
128	8,74	15,79546	97,4764	13,21007
129	10,84	15,34666	88,4924	14,4804
130	10,35	14,74942	44,4708	16,40015
131	3,61	15,56495	42,674	14,71955
132	7,99	14,07359	36,8344	17,22948
133	11,48	13,53922	42,2248	20,05974
134	14	16,14124	94,7812	12,85903
135	14,85	16,21633	105,562	12,361
136	3,87	16,16394	101,07	14,05915
137	8,84	16,32635	94,332	13,21007

Lote	Área	PCC	TCH	Fibra
138	8,75	16,21982	99,2732	12,26007
139	10,04	16,61449	96,578	13,13109
140	17,27	16,54289	87,594	13,40095
141	11,56	15,45144	86,6956	12,7603
142	13,59	12,96468	35,0376	16,56031
143	21,07	13,83435	40,8772	16,04911
144	18,43	13,80291	45,3692	18,91009
145	11,79	15,1144	76,8132	14,08109
146	3,44	14,34253	53,904	14,94992
147	1,85	15,59988	63,7864	14,62082
148	15,75	13,99152	44,92	15,32948
149	0,73	15,56146	73,2196	13,94068
150	4,52	15,15631	52,1072	13,51943
151	1,65	14,50668	79,5084	13,67959
152	3,79	14,43508	61,5404	15,39969
153	12,94	14,353	63,7864	14,30927
154	14,52	14,97819	53,904	15,64103
155	5,81	13,67543	59,7436	16,18075
156	4,53	13,5235	77,7116	17,88988
157	11,78	14,01247	71,4228	17,17024
158	11,09	15,22442	63,3372	13,90996
159	9,34	13,18821	36,8344	17,4796
160	7,59	14,15567	53,904	14,57913
161	11,46	14,00374	56,15	16,99034
162	5,43	15,51955	79,9576	13,15961
163	12,78	15,60686	74,118	11,56019
164	7,86	15,186	64,2356	12,88097
165	2,4	15,44096	53,904	11,34956
166	1,13	14,61321	103,316	13,22982
167	18,33	13,68766	55,7008	16,09957
168	19,11	13,28251	73,6688	16,04911
169	15,52	14,80006	97,4764	13,37024
170	3,49	15,69069	76,364	13,99991
171	16,45	13,82212	90,7384	12,90072
172	11,64	14,86468	85,7972	13,62913
173	6,3	14,6848	92,5352	14,32024
174	7,06	14,44731	84,8988	13,9692
175	16,74	15,19648	75,0164	13,89021
176	10,3	14,89611	86,2464	13,76077
177	3,94	14,05788	48,0644	13,92971
178	10,53	14,70227	57,4976	15,89992
179	4,9	15,35015	91,1876	13,69056
180	17,76	15,40953	75,0164	15,50939
181	8,94	15,24363	67,38	15,09911
182	7,09	15,98756	79,5084	11,88051
183	3,72	15,28205	67,8292	13,35927
184	10,83	15,51431	71,872	13,62913
185	5,76	15,5894	70,9736	12,52993
186	11,73	15,54225	82,2036	11,86076

Lote	Área	PCC	TCH	Fibra
187	5,18	15,44096	95,2304	13,10915
188	17,23	15,33967	89,3908	12,92924
189	15,55	15,25585	77,7116	14,07012
190	16,46	15,71513	67,38	14,03063
191	11,96	15,71688	80,4068	12,42901
192	6	14,26743	66,0324	16,68976
193	8	15,14409	52,1072	15,8692
194	10,92	15,12837	69,1768	15,20003
195	1,73	14,73021	42,2248	15,88017
196	6,8	14,27267	45,3692	16,93987
197	5,47	14,78435	69,1768	15,41066
198	21,59	14,49969	53,0056	16,45939
199	11,09	15,38508	43,1232	15,4304
200	6,01	14,65512	52,5564	18,60951
201	3,51	14,43857	101,9684	16,72047
202	1,03	14,37047	154,5248	16,3804
203	3,22	15,14758	168,0008	12,70984
204	1,97	15,81467	139,7012	10,66065
205	1,92	15,53002	89,84	16,161
206	5,86	15,48811	61,5404	15,39969
207	8,63	14,14345	66,0324	18,26066
208	7,35	15,93866	64,6848	12,78005
209	5,81	15,61909	70,0752	13,49091
210	10,38	15,65751	37,2836	15,7595
211	10,05	15,16155	65,134	15,80996
212	7,14	15,09519	69,1768	16,77094
213	5,07	15,21743	57,4976	14,89945
214	1,75	15,71513	70,5244	13,90996
215	2,69	15,54923	43,5724	12,70984
216	10,3	15,62083	72,3212	13,80904
217	12,28	14,91881	73,2196	15,25927
218	10,33	16,73673	73,2196	11,27935
219	0,62	16,42589	87,594	13,0894
220	4,58	16,42589	55,2516	13,0894
221	14,02	16,34556	73,2196	12,26007
222	16,12	16,34556	65,5832	12,26007
223	19,04	15,99105	59,7436	13,62913
224	18,99	16,32635	73,6688	13,67081
225	13,58	15,58241	64,6848	12,06042
226	19,79	16,32635	67,38	13,67081
227	3,4	15,99105	43,5724	13,62913
228	11,13	16,02772	53,904	12,7603
229	16,36	16,11853	61,5404	12,40926
230	6,51	15,53876	92,9844	12,22058
231	3,89	15,70116	95,2304	12,49044
232	4	14,66909	75,0164	13,99991
233	4,13	13,58113	81,7544	16,56909
234	12,14	14,84197	88,4924	15,27902
235	4,59	15,13885	72,7704	14,50015

Lote	Área	PCC	TCH	Fibra
236	9,31	14,06486	72,7704	15,03109
237	12,81	14,32157	64,2356	15,21978
238	6,46	13,08692	46,2676	14,85996
239	4,89	13,34014	43,1232	15,07936
240	6,15	13,45365	50,3104	14,66908
241	6,47	13,10788	52,1072	15,52036
242	3,19	12,75687	36,3852	14,07012
243	6,27	15,19124	69,626	14,21931
244	3,86	14,96072	75,9148	14,55938
245	17,52	16,16219	84,8988	14,41019
246	8,9	15,53526	78,1608	15,05962
247	14,18	16,03646	85,348	15,37994
248	11,66	15,9439	90,2892	14,9192
249	5,21	16,43636	112,3	13,90996
250	10,74	15,2576	89,3908	15,02012
251	6,34	14,0474	98,824	14,10084
252	11,21	16,00852	117,6904	14,57913
253	11,07	16,82754	108,7064	14,32901
254	12,87	13,0747	42,674	17,47082
255	10,28	15,21045	103,7652	13,26054
256	3,32	14,57479	27,4012	11,93097
257	18,15	14,75815	105,562	12,88975
258	6,56	15,18425	140,5996	13,9692
259	19,03	14,70925	60,1928	13,5304
260	15,55	15,27157	80,856	13,46019
261	8,23	13,85356	56,15	15,11008
262	10,68	14,2849	73,2196	15,18029
263	9,43	14,47175	50,3104	14,66908
264	8,96	14,02295	54,8024	16,54934
265	10,17	14,21155	71,4228	14,96089
266	10,16	14,40365	68,7276	15,03109
267	13,89	15,03407	138,8028	12,63086
268	4,8	14,31459	49,8612	13,94945
269	5	14,36872	69,1768	14,60107
270	6,49	12,34823	62,4388	16,18075
271	4,73	13,82212	60,1928	13,94945
272	4,36	12,34823	64,2356	14,8095
273	5,37	11,13803	59,7436	18,69946
274	3,84	14,77561	114,546	12,06919
275	8,75	12,84244	70,9736	16,4199
276	10,75	13,33839	45,8184	16,86089
277	5,44	13,75576	66,0324	14,9192
278	8,14	14,24124	69,1768	14,10961
279	4,38	13,87626	78,61	14,5901
280	5,62	14,19234	69,1768	14,53086
281	9,04	14,76863	76,364	12,20083
282	8,46	14,22378	95,2304	13,28906
283	8,43	14,27617	100,1716	13,51065
284	6,86	13,92516	207,9796	14,03063

Lote	Área	PCC	TCH	Fibra
285	6,94	13,96881	155,8724	14,60985
286	7,1	14,77736	71,4228	13,35927
287	8,61	14,54161	68,7276	13,6401
288	4,91	14,79133	50,3104	14,44091
289	5,59	15,10043	66,4816	14,64934
290	7,81	14,61844	22,0108	15,07059
291	17,12	16,67212	104,6636	14,57913
292	13,94	16,85723	90,2892	14,77001
293	5,09	14,95548	42,2248	13,69056
294	11,31	12,41634	44,4708	16,77971
295	8,77	13,88324	93,8828	15,79022
296	0,2	14,01946	203,9368	12,42901
297	4,19	13,63527	86,6956	13,67081
298	4,55	13,23711	78,1608	13,58086
299	8,2	13,99501	95,2304	13,55014
300	9,74	14,22552	111,4016	11,75984
301	10,56	13,40301	50,3104	14,78098
302	10,19	14,71624	110,5032	12,7603
303	1,02	14,11376	157,6692	13,40095
304	3,75	14,56431	113,1984	12,92924
305	6,07	14,05089	79,9576	13,28906
306	3,64	13,18472	103,316	13,80904
307	14	14,00549	84,0004	13,60938
308	15,24	13,95135	100,6208	14,41897
309	17,13	14,40365	73,2196	13,5304
310	3,19	13,72433	17,968	15,50061
311	1,88	14,57129	104,6636	12,43998
312	7,68	13,39602	61,0912	15,30973
313	5,64	13,761	50,3104	16,0908
314	13,04	15,69767	65,134	13,55892
315	3,64	15,85484	72,3212	13,49968
316	8,39	13,47111	51,658	14,73052
317	10,79	15,15456	80,856	14,05038
318	8,31	14,97819	80,4068	15,30973
319	12,97	15,02708	93,4336	14,85996
320	0,87	15,79896	85,348	10,88005
321	6,94	15,77975	66,0324	11,77081
322	7,71	16,3019	70,0752	10,7506
323	17,85	16,52892	61,0912	14,37948
324	11,79	15,69069	43,5724	14,50015
325	7,03	16,59877	61,9896	14,25003
326	13,62	16,52543	55,2516	13,8595
327	8,82	16,52543	56,15	13,8595
328	10,87	15,39206	88,9416	13,40973
329	8,43	16,64767	79,0592	13,30003
330	13,82	16,64767	54,8024	13,30003
331	8,68	15,069	52,1072	14,42994
332	17,87	16,65465	44,92	13,38998
333	10,44	16,65465	62,888	13,38998

Lote	Área	PCC	TCH	Fibra
334	11,01	16,65465	49,412	13,38998
335	12,05	16,65465	59,7436	13,38998
336	1,4	16,52717	63,3372	12,99945
337	10,55	16,52717	42,674	12,99945
338	12,88	16,52717	37,7328	12,99945
339	11,6	16,5848	52,5564	13,0894
340	1,88	14,81927	153,6264	13,92971
341	2,68	15,55447	90,7384	12,65938
342	1,83	15,85833	99,2732	13,49091
343	6,08	15,25061	110,054	12,92047
344	11	15,40429	107,3588	13,69934
345	5,58	15,66274	110,054	13,47994
346	20,63	15,58765	85,348	13,83975
347	18,16	15,62083	93,8828	14,28075
348	12,33	16,47828	114,0968	12,11966
349	20,59	15,91945	114,0968	12,81954
350	6,4	14,67607	142,8456	12,33028
351	5,15	15,42699	141,9472	12,70107
352	5,36	14,88738	154,0756	12,9095
353	20,24	15,93692	132,9632	11,54044
354	12,51	15,60686	140,1504	12,58917
355	11,81	15,73434	149,1344	11,86954
356	8,78	15,92818	140,1504	12,49044
357	32,61	16,3019	101,5192	12,70984
358	28,81	16,4451	119,038	12,20961
359	32,4	16,05741	116,792	12,51019
360	8,37	16,20236	112,7492	12,61989
361	6,35	16,33682	127,1236	12,79102
362	14,19	15,58591	103,7652	12,7603
363	6,04	15,26633	163,5088	12,85903
364	6,23	15,52304	90,2892	14,46065
365	15,56	14,22378	165,3056	11,25083
366	15,66	14,70227	160,8136	11,95949
367	15,99	14,13995	150,0328	11,38028
368	15,43	14,03343	172,0436	10,97
369	17,75	14,5905	143,744	11,29032
370	20,53	14,5678	136,1076	11,31007
371	13,04	14,86817	131,6156	11,50972
372	12,44	14,82276	136,5568	11,38905
373	8,65	14,45429	146,8884	11,48998
374	7,91	14,5224	117,6904	11,97046
375	10,53	14,49795	145,99	11,65892
376	10,59	14,84721	134,76	11,79056
377	20,98	14,52414	131,1664	11,79056
378	17,31	14,48922	129,3696	12,27104
379	11,18	14,6167	125,3268	12,20083
380	9,88	15,0917	118,1396	12,47947

