

LEONARDO PEREIRA FARDIN

**SISTEMA DE SUPORTE À DECISÃO NO PLANEJAMENTO FLORESTAL
ESTRATÉGICO**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do programa de Pós-Graduação em Ciência Florestal, para obtenção do título de Doctor Scientiae.

VIÇOSA
MINAS GERAIS – BRASIL
2019

Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa

T

F221s
2019 Fardin, Leonardo Pereira, 1982-
Sistema de suporte à decisão no planejamento florestal
estratégico / Leonardo Pereira Fardin. – Viçosa, MG, 2019.
vii, 98 f. : il. ; 29 cm.

Inclui anexo.

Orientador: Helio Garcia Leite.

Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Projetos de desenvolvimento florestal. 2. Programação
heurística. 3. Otimização combinatória. 4. GRASP (Sistema
operacional de computador). I. Universidade Federal de Viçosa.
Departamento de Engenharia Florestal. Programa de
Pós-Graduação em Ciência Florestal. II. Título.

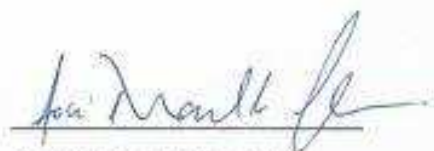
CDO adapt. CDD 22. ed. 634.9624

LEONARDO PEREIRA FARDIN

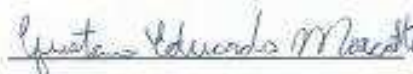
**SISTEMA DE SUPORTE À DECISÃO NO PLANEJAMENTO FLORESTAL
ESTRATÉGICO**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

APROVADA: 28/02/2019



José Marinaldo Gleriani



Gustavo Eduardo Marcatti



Daniel Henrique Breda Binoti



Carlos Antônio Alvares Soares Ribeiro



Helio Garcia Leite

(Orientador)

AGRADECIMENTOS

Agradeço a todos que de alguma forma contribuíram com o desenvolvimento deste trabalho, a CAPES, pela disponibilidade da bolsa de pesquisa, ao departamento de engenharia florestal (DEF), pela estrutura e apoio, a Universidade Federal de Viçosa, pela estrutura e excelência no ensino.

A equipe de coordenação da pós-graduação, Alexandre Amorim e Dilson, pelo auxílio nos prazos e marcações, muito obrigado.

Aos alunos da Ciência da Computação Fabio Martins, Matheus Aguilar e Marcos Valerio, vocês fizeram a diferença neste trabalho.

Ao professor Andre Gustavo dos Santos, pelas dicas valiosas e esclarecimentos durante o doutorado.

Ao professor Helio Garcia Leite, pelos esclarecimentos, ensinamentos e paciência, cada dia um aprendizado, muito obrigado por tudo.

Ao meu Pai Francisco de Assis Fardin, maior incentivador aos estudos, ídolo, obrigado pelo apoio e motivação diária.

Dedico a minha mãe Carmem Lucia Pereira Fardin.

A Deus, onde quer que o senhor esteja, muito obrigado.

BIOGRAFIA

LEONARDO PEREIRA FARDIN, filho de Carmen Lucia Pereira Fardin e Francisco de Assis Fardin, nascido em 28 de outubro de 1982 , na cidade de Vitória – ES , ingressou na Universidade Federal de Viçosa em 2001 para cursar graduação em engenharia florestal , concluindo em 2006, trabalhou com inventário e manejo florestal durante 6 anos no estado do Mato Grosso, voltando para Viçosa no ano de 2013 para fazer o mestrado em ciências florestais na Universidade Federal de Viçosa na área de manejo florestal , defendendo em fevereiro de 2015, no mesmo ano iniciou o doutorado em manejo florestal, este sendo concluído em fevereiro de 2019.

SÚMARIO

RESUMO	vi
ABSTRACT	vii
CAPÍTULO 1 – PRINCIPAIS META-HEURÍSTICAS E SUAS APLICAÇÕES NO PLANEJAMENTO FLORESTAL HIERÁRQUICO.	1
1 – Histórico do surgimento das heurísticas	1
2- Principais meta-heurísticas.....	2
2.1 – Meta-Heurísticas baseadas em uma única solução.....	3
2.1.1 - Busca tabu (BT)	5
2.1.2 - Simulated Annealing (SA)	7
2.1.3 - Variable Neighborhood Search (VNS).....	11
2.1.4 - Greedy Randomized Adaptive Search Procedures (GRASP).....	13
2.2 – Meta-Heurísticas baseadas na População.....	15
2.2.1 – Algoritmo Genético (AG)	17
2.2.2 – Enxame de partículas (OEP)	20
2.2.3 – Colônia de formigas (ACO)	23
2.3 - Outras meta-heurísticas.....	25
3 - Aplicações de meta-heurísticas no planejamento florestal hierárquico.	26
4 – Considerações finais.....	40
5 - Referências Bibliográficas.	41
CAPÍTULO 2 - UM SISTEMA DE SUPORTE A DECISÃO NO PLANEJAMENTO FLORESTAL ESTRATÉGICO.	50
1 - Introdução.....	50
2- Objetivos	51
3.1 - Definindo o problema	51
3.2 - Representação da solução	53
3.3 - Função de avaliação.....	53
3.4 - Preparando o arquivo de dados.	54
4- Resultados e Discussão	61
4.1 - Meta-Heurísticas implementadas.....	65
4.1.1 - Algoritmo Genético (AG).....	65
4.1.2 - Greedy Randomized Adaptive Search Procedures (Procedimentos de Busca gulosa aleatórios e adaptativos).....	68
4.1.3 - Simulated annealing (Recozimento Simulado).....	71
4.1.4 - Variable Neighborhood Search (Pesquisa de vizinhança variável).....	73
5 - Considerações Finais.....	76

6 - Referências Bibliográficas	77
CAPÍTULO 3 – IMPLEMENTAÇÃO DA META-HEURISTICA GRASP A UM PROBLEMA DE REGULAÇÃO FLORESTAL COM RESTRIÇÕES DE ADJACÊNCIA.....	80
1- Introdução.....	80
2 - Objetivos	81
3 - Material e Métodos.....	81
3.1 - Produção, receitas e custos.	82
3.2 - Formulação do problema e métodos utilizados.....	82
4 - Resultados e Discussão	86
6 - Referências Bibliográficas	94
Anexo I – Formulação do modelo matemático utilizando o AMPL do Cplex Studio 12.5.	96
Conclusões Gerais	98

RESUMO

FARDIN, Leonardo Pereira, D.Sc., Universidade Federal de Viçosa, fevereiro de 2019. **Um sistema de suporte e decisão no planejamento florestal estratégico**. Orientador: Helio Garcia Leite. Coorientador: André Gustavo dos Santos.

O objetivo do presente trabalho foi desenvolver uma interface para resolução de problemas de planejamento florestal estratégico utilizando meta-heurísticas (MH). No capítulo 1 foi feita uma revisão de literatura sobre as principais MH aplicadas no planejamento florestal estratégico. No capítulo 2 foi descrito o sistema desenvolvido além das MH implementadas. Para o desenvolvimento da interface e das MH foi utilizada a linguagem de programação C# e o visual studio 2017 como ide. Para a formulação do problema foi utilizada a programação linear inteira mista (PLIM). Foram implementadas: algoritmo genético (AG), Simulated annealing (SA), Variable Neighborhood Search (VNS) e Greedy Randomized Adaptive Search Procedures (GRASP). Para validação dessas MH foi desenvolvida uma instância hipotética baseada em um SIG, sendo extraídas informações espaciais como distância a fábrica, talhões vizinhos e distâncias entre os talhões. Finalmente, no capítulo 3 apresentamos uma comparação da GRASP, com três alternativas de busca local, com o método exato branch and bound, o software utilizado foi o Cplex Studio 12.5. A maior eficiência relativa foi obtida ao empregar GRASP + VNS. A interface desenvolvida resolveu problemas de otimização do planejamento florestal estratégico com eficiência e pode ser utilizado para resolução de problemas similares. Há possibilidade de expansão da interface, como a implementação de mais restrições, geração de novos gráficos para melhor controle das áreas e custos.

ABSTRACT

FARDIN, Leonardo Pereira, D.Sc., Universidade Federal de Viçosa, February, 2019. **A support and decision system in strategic forest planning**. Advisor: Helio Garcia Leite. Co-adviser: André Gustavo dos Santos.

The objective of the present work was to develop an interface for solving strategic forestry planning problems using metaheuristics (MH). In chapter 1 a literature review was done on the main MH applied in strategic forestry planning. In chapter 2 the system developed beyond the implemented MH was described. For the development of the interface and the MH was used the programming language C # and visual studio 2017 as ide. For the formulation of the problem, mixed linear programming (PLIM) was used. Genetic algorithm (GA), simulated annealing (SA), Variable Neighborhood Search (VNS) and Greedy Randomized Adaptive Search Procedures (GRASP) were implemented. For the validation of these MHs, a hypothetical instance was developed based on a GIS, with spatial information being extracted such as distance to the factory, neighboring stands, and distances between stands. Finally, in chapter 3 we present a GRASP comparison, evaluating three local search alternatives, comparing with the exact branch and bound method, using Cplex Studio 12.5 software. The higher relative efficiency was obtained by using GRASP + VNS. The interface developed solved problems of optimization of strategic forestry planning efficiently and can be used to solve similar problems. It is possible to expand the interface, such as implementing more restrictions, generating new graphics for better control of areas and costs.

CAPÍTULO 1 – PRINCIPAIS META-HEURÍSTICAS E SUAS APLICAÇÕES NO PLANEJAMENTO FLORESTAL HIERÁRQUICO.

1 – Histórico do surgimento das heurísticas

Alan Turing foi provavelmente um dos primeiros a usar uma heurística, durante a segunda guerra mundial, quando ele quebrou as cifras do enigma alemão. Turing, junto com o britânico matemático Gordon Welchman, em 1940, projetaram uma máquina eletromecânica criptanalítica, a bomba, para ajudar seu trabalho de quebra de código, a bomba utilizou uma heurística, assim chamado por Turing, para procurar entre cerca de 10^{22} possíveis combinações, a possível configuração correta codificada em uma mensagem enigma (YANG, 2010).

A palavra heurística tem sua origem na palavra grega heuriskein, que significa a arte de descobrir novas estratégias (regras) para resolver problemas. O sufixo meta é também uma palavra grega, que significa “metodologia de nível superior”. O termo meta-heurística foi introduzido por Fred Glover em seu trabalho publicado em 1986. Métodos de busca meta-heurística podem ser definidos como métodos gerais de nível superior que podem ser usados como estratégias de orientação na concepção de heurísticas subjacentes, para resolver problemas específicos de otimização (TALBI, 2009).

Heurísticas, ou seja, técnicas de solução aproximadas, foram utilizadas desde o início do uso de pesquisa operacional, para analisar problemas combinatórios difíceis. Com o desenvolvimento da teoria da complexidade no início da década de 1970, tornou-se claro que, uma vez que a maioria desses problemas eram realmente NP- difíceis, havia pouca esperança de encontrar soluções eficientes para esses problemas (GENDREAU e POTVIN, 2014).

Embora muitas abordagens diferentes tenham sido propostas, as mais populares foram baseadas na Hill-Climbing, que pode ser resumido como um procedimento de busca iterativa pelo qual, a partir de uma solução viável inicial, melhora progressivamente a solução aplicando uma série de modificações ou movimentos locais. Por esta razão, Hill-Climbing está na família dos métodos de busca local. Em cada iteração, a busca se move para uma solução viável melhorada, que difere apenas um pouco da atual. A busca termina quando não é possível melhorar a solução do problema. Neste ponto, tem-se um ótimo local em relação às modificações locais consideradas pelo método Hill-Climbing. (GENDREAU e POTVIN, 2014).

2- Principais meta-heurísticas

Uma classificação rigorosa das diferentes meta-heurísticas é uma tarefa difícil e arriscada. Glover e Laguna (1997), comentaram que os principais defensores de métodos alternativos geralmente diferem entre eles sobre a natureza essencial dos métodos que defendem.

Glover e Laguna (1997) consideram a classificação das meta-heurísticas, em termos de suas características, em relação a três opções básicas de design:

- (1) o uso da memória adaptativa,
- (2) o tipo de exploração de vizinhança utilizada,
- (3) o número de soluções atuais realizadas a partir de uma iteração para a próxima.

Esses autores propuseram um esquema de classificação no formato $x/y/z$, onde as escolhas para x são A (emprega adaptação memória) e M (sem memória). As escolhas para y são N (método que emprega alguma busca sistemática de vizinhança, quer seja para selecionar o próximo, mover ou melhorar uma determinada solução), S (métodos baseados em amostragem aleatória) e z , que pode ser 1 (método se move de uma solução atual para o próximo após cada iteração) ou P (método baseado na população de tamanho P). Além dos três elementos de design básicos utilizados na classificação, as meta-heurísticas incorporam outras estratégias com o objetivo de orientar a busca para fugir dos ótimos locais.

Sendo assim muitos critérios de classificação das meta-heurísticas são encontrados, Talbi (2009), comentou sobre as principais classes e suas diferenças:

Inspiradas na natureza versus não inspiradas na natureza:

Os algoritmos evolutivos e sistemas imunológicos artificiais são inspirados por processos da biologia; Formigas, colônia de abelhas e enxame de partículas de inteligência em diferentes espécies (Ciências sociais).

Uso de memória versus métodos sem memória:

Alguns algoritmos meta-heurísticos não têm memória; ou seja, nenhuma informação extraída dinamicamente é usada durante a busca. Alguns representantes desta classe são busca local, Grasp e Simulated Annealing. Outras meta-heurísticas usam uma memória que contém algumas informações extraídas durante a pesquisa. Por exemplo, as memórias de curto prazo e longo prazo na busca tabu.

Determinística versus estocástica:

A primeira resolve um problema de tomada decisão determinística (por exemplo, busca local, Busca tabu). Nesse caso, o uso da mesma solução inicial leva a uma mesma solução final. Em meta-heurísticas estocásticas, algumas regras aleatórias são aplicadas durante a busca (por exemplo, simulated annealing, algoritmos evolutivos). Nas meta-heurísticas estocásticas podem ser obtidas diferentes soluções finais da mesma solução inicial. Nesse caso, esta característica deve ser levada em consideração ao avaliar o desempenho dos algoritmos.

Busca baseada em população versus busca baseada em solução única:

Algoritmos baseados em solução única (por exemplo, busca local e simulated annealing) manipulam e transformam uma única solução durante a pesquisa, com o poder de intensificar a busca nas regiões locais. Naqueles baseados na população (por exemplo, enxame de partículas e algoritmos evolutivos), toda uma população de soluções é avaliada, permitindo uma melhor diversificação em todo o espaço de busca.

Iterativo versus construtivas:

Em algoritmos iterativos, inicia-se com uma solução completa (ou população de soluções). As transformações são feitas em cada iteração usando alguns operadores de busca. Nos algoritmos construtivos o processo começa a partir de uma solução vazia. Em cada passo uma variável de decisão do problema é assinalada até que uma solução completa seja obtida. A maioria das meta-heurísticas são algoritmos iterativos.

Aqui seguiremos a classificação com base na busca em solução única e busca baseada em população, lembrando que os algoritmos pertencentes a cada família de meta-heurísticas compartilham muitos mecanismos de busca em comum.

2.1 – Meta-Heurísticas baseadas em uma única solução.

As meta-heurísticas baseadas em uma única solução possuem alguns conceitos comuns, segundo Talbi (2009), estes conceitos são:

a - Solução inicial – uma solução inicial pode ser fornecida aleatoriamente ou empregando alguma heurística gananciosa.

b - Vizinhança – a vizinhança tem um impacto importante na performance. A interdependência entre representação da solução e vizinhança não deve ser esquecida.

c - Avaliação incremental – esse é um aspecto importante na eficiência das meta-heurísticas de uma solução, que consiste em avaliar somente a transformação aplicada a solução do que uma avaliação completa da vizinhança.

d - Critério de parada – existem diferentes critérios de parada como, número máximo de iterações, a solução encontrada não foi melhorada após um determinado número de iterações, uma solução alvo da função da avaliação (qualidade), e podem ser usados critérios combinados.

Para ilustrar os conceitos comuns e suas relações com as meta-heurísticas de solução única veja a Figura 1, onde constam as estratégias e suas particularidades.

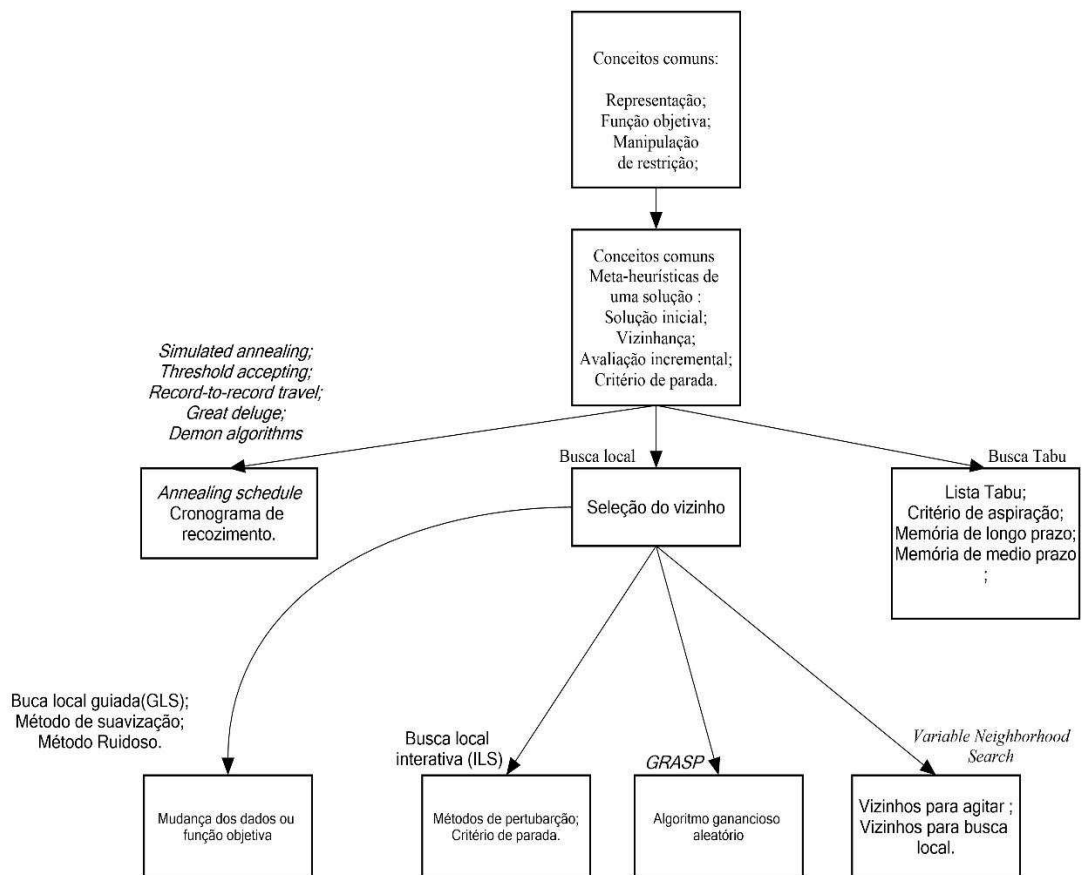


Figura 1 - Família de algoritmos de solução única e suas estratégias para melhorar a busca local e escapar do ótimo local. Adaptado de Talbi (2009).

Para melhor entendimento dos algoritmos, uma breve explicação dos seus principais componentes é apresentada a seguir para as meta-heurísticas de solução única: Busca tabu, Simulated annealing, Variable Neighborhood Search (VNS) e Grasp.

2.1.1 - Busca tabu (BT)

O método Busca Tabu (BT) pode ser considerado como uma técnica baseada em conceitos selecionados da inteligência artificial. BT é um procedimento heurístico geral para orientar uma pesquisa visando obter boas soluções em espaços complexos de solução (GLOVER e TAILLARD, 1993). É um método heurístico genérico, proposto por Glover em (1986) e detalhado por Glover e Laguna (1997). Em vários casos, os métodos descritos fornecem soluções muito próximas da ótima e estão sendo muito eficazes, para resolver problemas difíceis. Devido a esse sucesso a meta-heurística BT tem sido utilizada com certa frequência, para tratar de problemas combinatórios, em muitos cenários práticos (GENDREAU, 2010).

O princípio básico do BT é perseguir a busca local sempre que encontrar um ótimo local, permitindo movimentos que não melhoram. Movimentos cíclicos de visita as mesmas soluções são evitados pelo uso de memórias, chamadas de listas tabu, que registram a história da busca (GENDREAU, 2010). Segundo Glover (1990), BT baseia-se no uso de estruturas flexíveis de memória baseadas em atributos, projetadas para permitir que os critérios de avaliação e informações históricas de pesquisa sejam explorados de forma mais completa do que por restrições de memória rígidas, um mecanismo de controle associado - para empregar a estrutura da memória - com base na interação entre condições que restringem e liberam o processo de pesquisa (incorporado em listas tabu e critérios de aspiração), a incorporação de funções de memória de diferentes períodos de tempo, de curto a longo prazo, para implementar estratégias com o propósito de intensificar e diversificar a busca.

A propriedade que distingue a BT de outras meta-heurísticas é o uso sistemático de uma memória adaptativa. A memória atualiza o armazenamento de elementos de soluções ou de soluções completas encontradas durante a exploração do espaço de soluções (ARMENTANO e BRANCHINI, 2013).

Atributos selecionados de soluções visitadas recentemente são denominados tabu-ativo. Os movimentos que levam a soluções que contém atributos tabu-ativos tornam-se proibidos, isto é, são tabu por um determinado período ou número de iterações, denominado duração tabu. O principal motivo de incluir esta restrição tabu na vizinhança é para permitir que o método tenha alternativas para escapar dos ótimos locais, evitando ciclos periódicos com as mesmas soluções (ARMENTANO e BRANCHINI, 2013).

Embora essenciais, os tabus, podem proibir mesmo quando não há perigo de ciclismo ou podem levar a uma estagnação geral do processo de busca. Assim, é necessário utilizar dispositivos que permitam cancelar os tabus. Estes são chamados de critério de aspiração, o mais simples, encontrado em quase todas as implementações de BT, consiste em permitir um movimento, mesmo que seja tabu, se resultar em uma solução com um valor da função objetivo avaliada mais elevada que o da solução conhecida (GENDREAU, 2010). Na Figura 2 é apresentado o fluxograma do algoritmo BT.

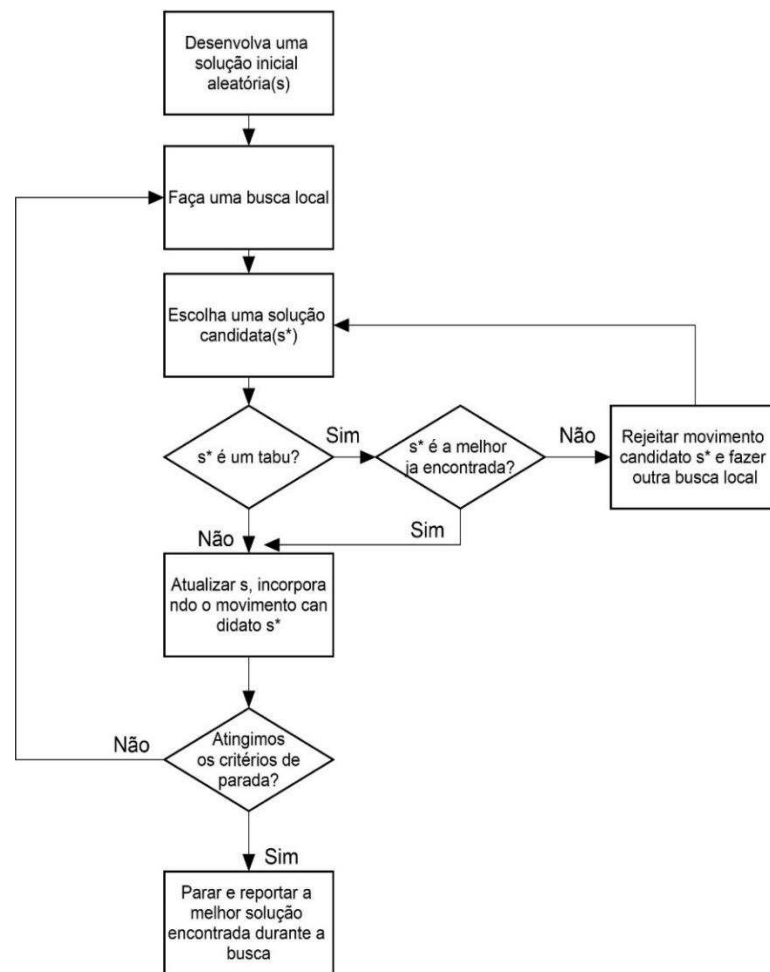


Figura 2 - Fluxograma do processo de busca do algoritmo Busca Tabu. Adaptado de Bettinger et al. (2002).

Alguns mecanismos avançados são comumente introduzidos na BT para lidar com a intensificação e diversificação da busca. A intensificação está relacionada a memória de médio prazo, que armazena as melhores soluções encontradas durante a busca. A ideia é dar prioridade as melhores soluções encontradas, geralmente com alguma probabilidade ponderada associada. A diversificação está associada a memória de longo prazo. Ela armazena informações sobre as soluções visitadas ao longo da busca e explora as áreas

não visitadas no espaço de soluções (TALBI, 2009). O modelo de um algoritmo de BT básico adaptado de Jaziri (2008), é:

Algoritmo Busca Tabu em pseudocódigo:
(Selecionar s , uma solução inicial qualquer);
($T := []$; Lista tabu vazia)
 $s^* \leftarrow s$
Repita
Encontrar a melhor solução admissível s' ;
Se $f(s') > f(s^*)$ **então** $s^* \leftarrow s'$
 $s \leftarrow s'$;
Atualize a lista tabu T ;
Até Critério de parada;
Saída melhor solução encontrada;
Fim;

2.1.2 - Simulated Annealing (SA)

A meta-heurística Simulated Annealing (SA), aplicado a problemas de otimização, surgiu dos trabalhos de Kirkpatrick et al. (1983) e de Cerny (1985). Esses autores demonstraram como o modelo proposto por Metropolis et al. (1953), para simular o recozimento de sólidos, poderia ser utilizado para problemas de otimização. O principal impacto no campo da pesquisa heurística foi a simplicidade e eficiência da SA na resolução de problemas de otimização combinatória (TALBI, 2009).

SA recebe o seu nome de recozimento devido a um processo mecânico de recozimento de metais. Se um metal diminuir a temperatura rapidamente, não são dados aos átomos uma possibilidade de estabelecer-se em um treliço apertado e são congelados em uma configuração aleatória, resultando em um metal frágil. Se diminuir a temperatura lentamente, é dado tempo suficiente para os átomos se estabelecerem em um cristal forte (LUKE, 2013). O algoritmo de SA simula as mudanças de energia em um sistema submetido a um processo de arrefecimento, até que ocorra convergência para um estado de equilíbrio (estado congelado estável) (TALBI, 2009).

Para implementar o algoritmo SA, existem quatro principais escolhas que devem ser feitas, tipo de representação das soluções, definição de uma função de custo, definição de um mecanismo para gerar os vizinhos, como projetar um cronograma de resfriamento. O cronograma de resfriamento possui quatro parâmetros que precisam ser especificados: a temperatura inicial, uma regra de atualização da temperatura, o número de iterações a

serem feitas em temperatura e um critério de parada da busca (PHAM e KARABOGA, 2012). Para ilustrar o procedimento observe a Figura 3, onde é apresentado um fluxograma do algoritmo de otimização SA.

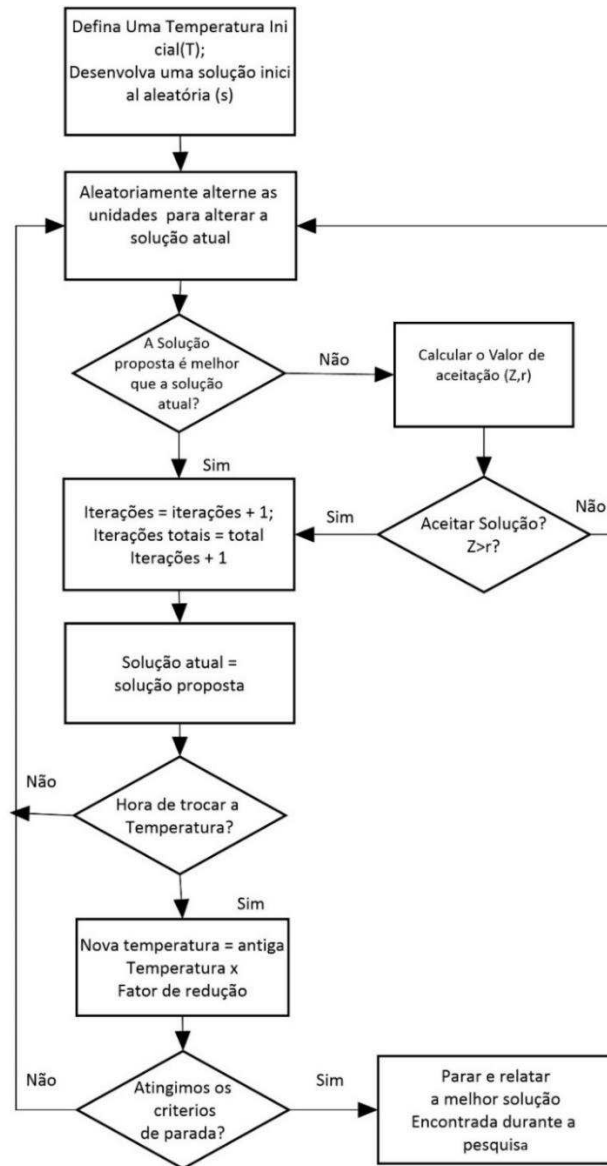


Figura 3 - Fluxograma do processo de busca do algoritmo Simulated annealing. Adaptado de Bettinger et al. (2002).

SA é um algoritmo de busca local capaz de escapar de ótimos locais, aceitando movimentos que piorem a solução corrente. A facilidade de implementação, as propriedades de convergência e o uso de movimentos de subida Hill-Climbing, com o objetivo de escapar de ótimos locais, contribuíram para que se tornasse uma técnica muito popular na otimização combinatória (HENDERSON et al., 2003).

Em cada iteração de um algoritmo SA, aplicado a um problema de otimização discreta, a função de aptidão gera valores para duas soluções: a corrente e a solução recém-selecionada. Estes valores são então comparados. Uma melhora na solução atual é sempre aceita, enquanto que uma fração de soluções inferiores é também aceita na esperança de escapar de ótimos locais. A probabilidade de aceitar uma solução inferior depende do parâmetro de temperatura, que é decrescente com cada iteração do algoritmo. (HENDERSON et al., 2003). Altas temperaturas aumentam a chance de aceitação de uma solução de pior qualidade enquanto que baixas temperaturas limitam essa probabilidade de aceitação (RODRIGUEZ et al., 2004).

Barão et al. (2013), apresentaram o algoritmo proposto por Metropoles et al. (1953) que é descrito a seguir:

Dado um estado corrente i com o material de energia E_i , o estado j será gerado por uma perturbação que transforma o estado corrente em E_j , agora com uma pequena variação. A cada valor de E_j , é testada a variação de energia do valor da função de aptidão isto é:

$$\Delta E = E_j - E_i$$

em que :

$\Delta E < 0$: houve redução de energia, ou seja a nova solução é menor que a anterior (para problemas de minimizar). Logo E_j passa a ser a nova solução corrente.

$\Delta E > 0$: houve um aumento de energia, a aceitação desse tipo de solução depende de uma probabilidade conhecida como “critério de metrópolis” calculada pela função:

$$p(\Delta E) = \exp\left(\frac{-\Delta EK}{T}\right)$$

T é a temperatura do corpo e K a constante de Boltzmann. O processo inicia com um alto valor de T , dando maior probabilidade de uma solução de piora da solução atual ser aceita.

O aceite de uma nova solução é automático caso acarrete redução no valor da função. Caso contrário, um critério probabilístico é utilizado, sendo a função de aceite dada por:

$$p = \exp\left(\frac{-\Delta E}{T}\right)$$

Um número randômico r é gerado, no intervalo de $(0,1)$. Se este número for menor ou igual a p , aceita-se a solução, caso contrário, a solução é rejeitada.

A meta-heurística SA, adaptado de Eglese (1990) é:

Algoritmo Simulated Annealing em pseudocódigo:

(Selecionar s , uma solução inicial qualquer);
 (Ajustar $k=0$ para o contador de mudança de temperatura)
 (t_k é a taxa de resfriamento)
 (Selecione uma temperatura T inicial >0);
 (M_k , é o cronograma de repetição, que define o número de iterações executadas em cada temperatura, t_k)

Repita

Definir contador de repetição $m = 0$

Repita

Gerar a solução s' de s , um vizinho de s ;

Calcular a variação de energia

$$\Delta E = f(s') - f(s)$$

Se $\Delta E > 0$ **então** $s \leftarrow s'$

Se $\Delta E < 0$

Gerar $r \in \text{Unif}[0,1]$

Se

$$r < z = e^{(f(s') - f(s)) / T}$$

Então $s \leftarrow s'$ com a probabilidade $e^{(-\Delta E / T)}$

$m \leftarrow m + 1$

Até $m = M_k$

$k \leftarrow k + 1$

Até critério de parada seja atingido;

Saída melhor solução encontrada;

Fim;

A Tabela 1 ilustra a analogia entre o sistema físico e o problema de otimização. A função de aptidão do problema é análoga ao estado energético do sistema. Uma solução do problema de otimização corresponde a um estado do sistema. As variáveis de decisão associadas a uma solução do problema são análogas as posições moleculares.

Tabela 1 - Analogia entre o sistema físico e o problema de otimização empregando SA.

Sistema Físico	Problema de otimização
Estado do Sistema	Solução
Posições moleculares	Variáveis de decisão
Energia	Função objetivo
Estado fundamental	Solução ótima
Estado estável	Ótimo local
Resfriamento Rápido	Busca local
Controle de Temperatura	Parâmetro T
Recozimento cuidadoso	Recozimento Simulado

Adaptado de Talbi (2009).

2.1.3 - Variable Neighborhood Search (VNS)

A meta-heurística Variable neighborhood search (VNS), no português busca de vizinhança variável, surgiu do trabalho de Mladenović e Hansen (1997). Os autores propuseram uma rotina de mudança de vizinhança na busca e uma rotina de busca local, para resolver problemas de natureza combinatória. Sua eficácia foi ilustrada no problema do caixeiro viajante, originando esta meta-heurística.

A busca de vizinhança variável (VNS) é uma meta-heurística para a solução de problemas de otimização combinatória e global, cuja ideia básica é a sistemática mudança de vizinhança, dentro de uma fase de descida ou subida, dependendo do problema, para encontrar um ótimo local seguida de uma fase de perturbação para sair do vale correspondente (HANSEN et al., 2010).

O VNS é um algoritmo estocástico, pelo qual, inicialmente, um conjunto de estruturas de vizinhança N_k ($k = 1, \dots, n$) é definido. Em cada iteração, tem-se três etapas: agitação, busca local e movimento, uma solução inicial é agitada da atual vizinhança N_k . Por exemplo, uma solução x' é gerada aleatoriamente na atual vizinhança $N_k(x)$. Um procedimento de busca local é aplicado a solução x' para gerar a solução x'' . A solução atual é substituída pelo novo ótimo local x'' somente se uma solução melhor foi encontrada. O mesmo procedimento de busca é então reiniciado a partir da x'' na primeira vizinhança N_1 . Se nenhuma solução melhor for encontrada (ou seja, $f(x'') \geq f(x)$), o algoritmo move para o próximo vizinho N_{k+1} , gera aleatoriamente uma nova solução nesta vizinhança, e tenta melhorar a solução (TALBI, 2009).

Para ilustrar o procedimento observe a Figura 4, onde é apresentado um fluxograma do algoritmo de otimização VNS.

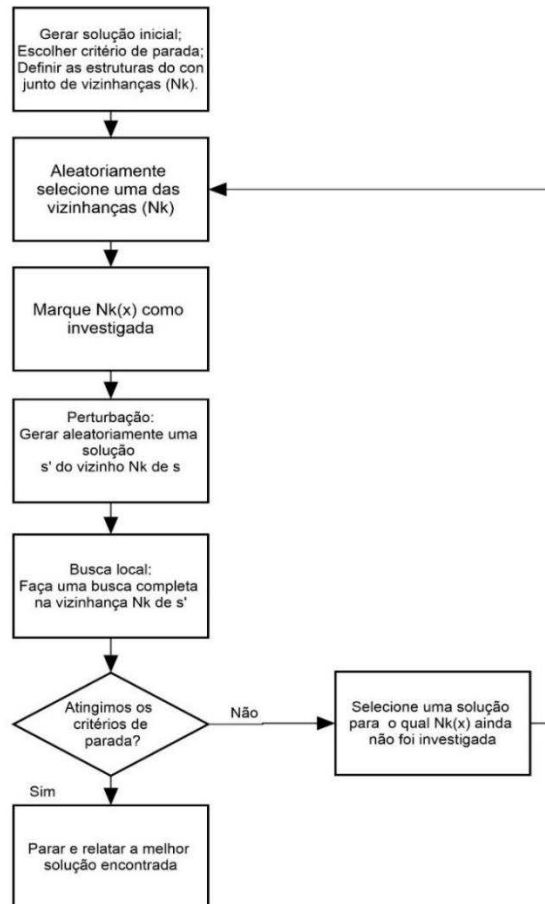


Figura 4 - Fluxograma do processo de busca do algoritmo Variable Neighborhood Search. Adaptado de Liang et al. (2009).

Conforme Talbi (2009), adaptado, o modelo de um algoritmo VNS básico pode ser descrito assim:

Algoritmo Variable Neighborhood Search em pseudocódigo:

Entrada: um conjunto de estruturas de vizinhança N_k para $k = 1, \dots, k_{max}$ para agitação.

Gerar a solução inicial; $s = s_0$

Repita

$k = 1$;

Repita

Agitação: escolha uma solução aleatória s' da vizinhança k^{th} , $N_k(s)$ de s ;

$s'' =$ busca local (s')

Se $f(s'') > f(s)$ **então** $s'' \leftarrow s'$;

Continue a busca com N_1 ; $k = 1$;

Caso contrário $k = k + 1$;

Até $k = k_{max}$;

Até Critério de parada seja atingido;

Saída melhor solução encontrada;

Fim.

2.1.4 - Greedy Randomized Adaptive Search Procedures (GRASP)

A meta-heurística GRASP (Greedy Randomized Adaptive Search Procedure), foi proposta por Feo e Resende (1995). Esses autores definiram os principais componentes da meta-heurística e demonstraram passo a passo como aplicar o GRASP a problemas de otimização combinatória, apresentam, ainda, uma breve revisão bibliográfica e aplicaram a dois problemas industriais, um de cobertura e outro de planejamento e programação de produção.

GRASP é um processo iterativo, ou de multi-start, onde cada iteração consiste em duas fases: uma de construção e uma de busca local. A fase de construção gera uma solução viável. Em seguida a vizinhança dessa solução é explorada até um mínimo local, na fase de busca local, sendo a melhor solução mantida como resultado (REZENDE e RIBEIRO, 2002).

Esta meta-heurística utiliza as melhores características dos algoritmos gulosos e procedimento aleatórios, para construção das soluções iniciais, refinadas em seguida por uma fase de busca local (BARROS JUNIOR et al., 2009).

Nas heurísticas construtivas, em cada iteração, os elementos podem ser incluídos em uma lista parcial de soluções, ordenadas em ordem decrescente. A partir dessa lista, um subconjunto é gerado representando a lista restrita de candidatas RCL, é a chave principal da meta-heurística GRASP, que representa o aspecto probabilístico da mesma (TALBI, 2009).

Conforme este autor, o critério de restrição pode ser definido de duas formas. Na primeira, critério de cardinalidade básico, a RCL é composta por p melhores elementos em termo de incremento de custo. Na segunda os critérios são definidos com base em valores. É a estratégia mais utilizada, que consiste em selecionar soluções que são melhores dentro de um limite em um intervalo de valores. Consiste em selecionar as soluções que são melhores do que um determinado valor limite. Para ilustrar o procedimento observe a Figura 5, onde é apresentado um fluxograma do algoritmo de otimização GRASP.

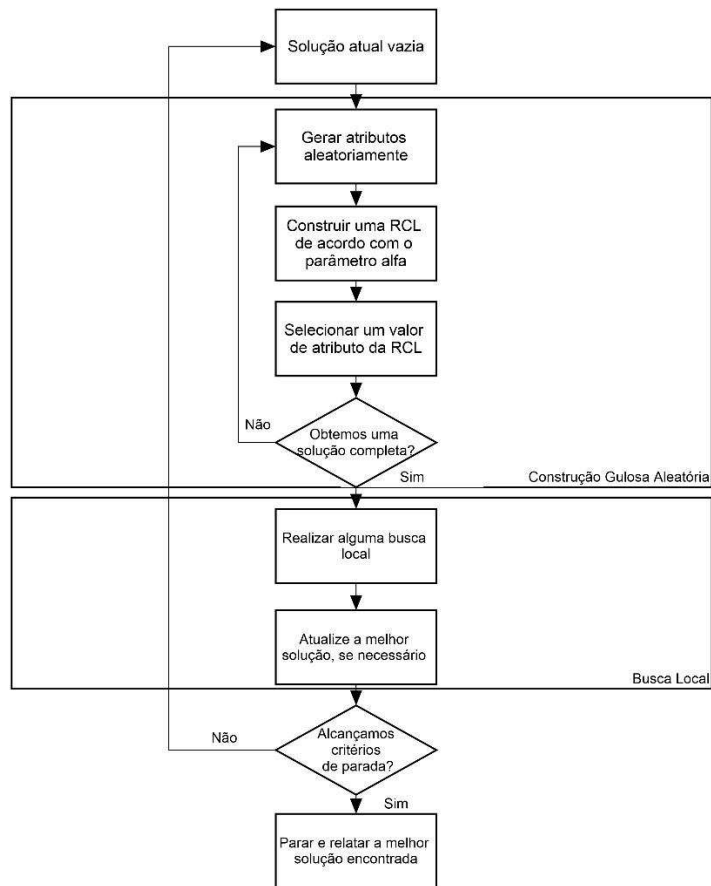


Figura 5 - Fluxograma do processo de busca do algoritmo Grasp. Adaptado de Yin e Wang (2012).

Feo e Resende (1995), relatam que a chave para o sucesso de um algoritmo de busca local está na adequação da escolha de uma estrutura de vizinhança, as técnicas de buscas nessa vizinhança eficientes e solução inicial. Conforme Rezende e Ribeiro (2010), o modelo de um algoritmo Grasp básico pode ser descrito assim:

Algoritmos Grasp em pseudocódigo:

Ler a entrada ();

Para $k = 1 \dots$, máximo de interações **faça**

$s \leftarrow$ Construção aleatória gulosa ;

se a solução não é viável **então** ;

$s \leftarrow$ repare a solução;

fim;

$s \leftarrow$ Busca local (s);

Atualize a solução com a melhor solução encontrada;

Fim;

Atualize; Melhor solução;

Fim.

O principal parâmetro para Grasp é o α ($\alpha \in [0, 1]$), que expressa o compromisso entre a exploração de busca (intensificação usando mais ganância) e pesquisa de exploração (diversificação usando mais aleatoriedade). Pequenos valores para α permitem valores maiores para a qualidade média dos elementos da lista RCL e, incentiva a exploração. Quando $\alpha = 1$, o algoritmo é ganancioso determinista. Quando $\alpha = 0$, o algoritmo é ganancioso aleatório. Valores menores para α geram mais elementos na lista RCL e incentivam a diversificação (TALBI, 2009). Conforme o autor, o desempenho da meta-heurística é muito sensível ao parâmetro α . Três estratégias podem ser aplicadas para inicialização do parâmetro α : estratégia estática, o valor de α é inicializado com um valor constante, estratégia dinâmica, em que um valor aleatório é atribuído a α , a cada iteração, e ainda a estratégia adaptativa quando o valor de α é auto ajustado.

2.2 – Meta-Heurísticas baseadas na População

Além dos conceitos comuns a todas as meta-heurísticas (representação da solução, uma função de aptidão e tratamento de restrições), existem alguns conceitos comuns para meta-heurísticas baseadas na população, conforme Talbi (2009):

População inicial: Uma população inicial pode ser especificada aleatoriamente, ou por um certo procedimento (por exemplo, diversificação sequencial, diversificação paralela e heurística).

Critérios de parada: além dos critérios tradicionais de parada de meta-heurísticas de única solução, os critérios de parada em meta-heurísticas populacionais podem definidos com base em algumas estatísticas da população (por exemplo, diversidade populacional) ou na evolução de uma população.

Ainda segundo o autor, na etapa de geração de uma nova população, de acordo com a estratégia de geração, estas meta-heurísticas podem ser classificadas em duas classes principais:

i - Baseado na evolução: nas meta-heurísticas populacionais evolutivas, como algoritmos evolutivos, evolução diferencial, scatter search, e sistemas imunológicos artificiais (seleção clonal), as soluções que compõem a população são selecionadas e reproduzidas com variação de operadores como (crossover, mutação), atuando diretamente em suas representações, uma nova população é construída a partir dos diferentes atributos de soluções pertencentes a população atual.

ii - Baseados em quadro negro - Em meta-heurísticas populacionais, como otimização de colônia de formigas e enxames de partículas as soluções da população participam da construção de uma memória compartilhada, essa memória compartilhada será a entrada principal na construção de uma nova população de soluções (por exemplo, modelo probabilístico, trilhas de feromônios, melhor global (gbest)).

A Figura 6 ilustra o processo de desenvolvimento das meta-heurísticas populacionais.

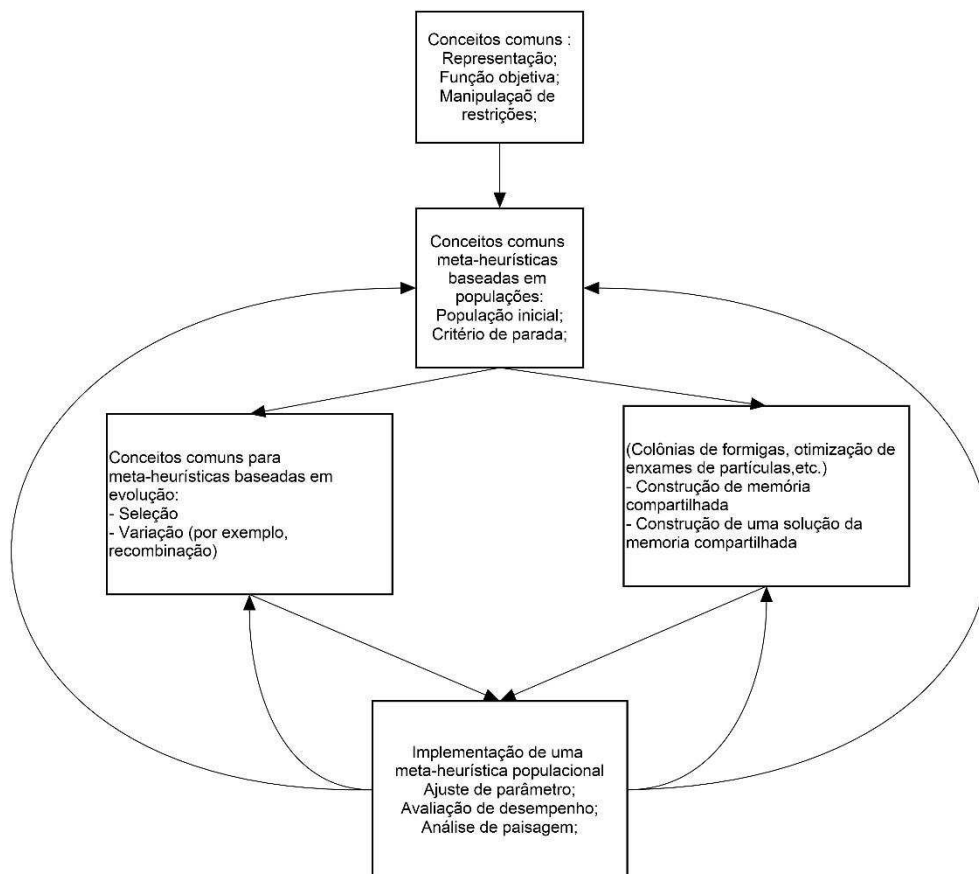


Figura 6 - Processo de desenvolvimento de meta-heurísticas populacionais. Adaptado de Talbi (2009).

Para melhor entendimento dos algoritmos, uma breve explicação dos principais componentes é apresentada a seguir para as meta-heurísticas populacionais algoritmos genéticos, enxame de partículas e colônia de formigas.

2.2.1 – Algoritmo Genético (AG)

A computação evolutiva foi introduzida na década de 1960 por I. Rechenberg no trabalho "Estratégias de evolução", sendo a ideia desenvolvida para outras pesquisas. O algoritmo genético (AG) foi inventado por John Holland (1975), que desenvolveu a ideia em seu livro "Adaptação em sistemas naturais e artificiais". O autor propôs AG como um método heurístico baseado na "sobrevivência do mais apto" (SIVANANDAM e DEEPA, 2007).

Com o sucesso do AG, outros algoritmos que fazem uso do princípio de evolução natural também foram surgindo, como exemplo, evolução estratégica, e programação genética. A classificação dos diferentes algoritmos nem sempre é clara, os algoritmos em conjunto, são denominados algoritmos evolutivos (SIVANANDAM e DEEPA, 2007).

O AG é um algoritmo de otimização numérica inspirado tanto na seleção natural quanto na genética natural. Aplicáveis a uma ampla gama de problemas (COLEY, 1999). Ainda segundo o autor um algoritmo de AG típico consiste em:

Um número ou uma população de possíveis soluções para o problema, uma forma de calcular como as soluções individuais dentro da população é boa ou ruim, um método para misturar fragmentos das melhores soluções para formar novos, sobre soluções médias ainda melhores, e um operador de mutação para evitar a perda permanente de diversidade dentro das soluções. Um fluxograma de busca do AG clássico é apresentado na Figura 7.

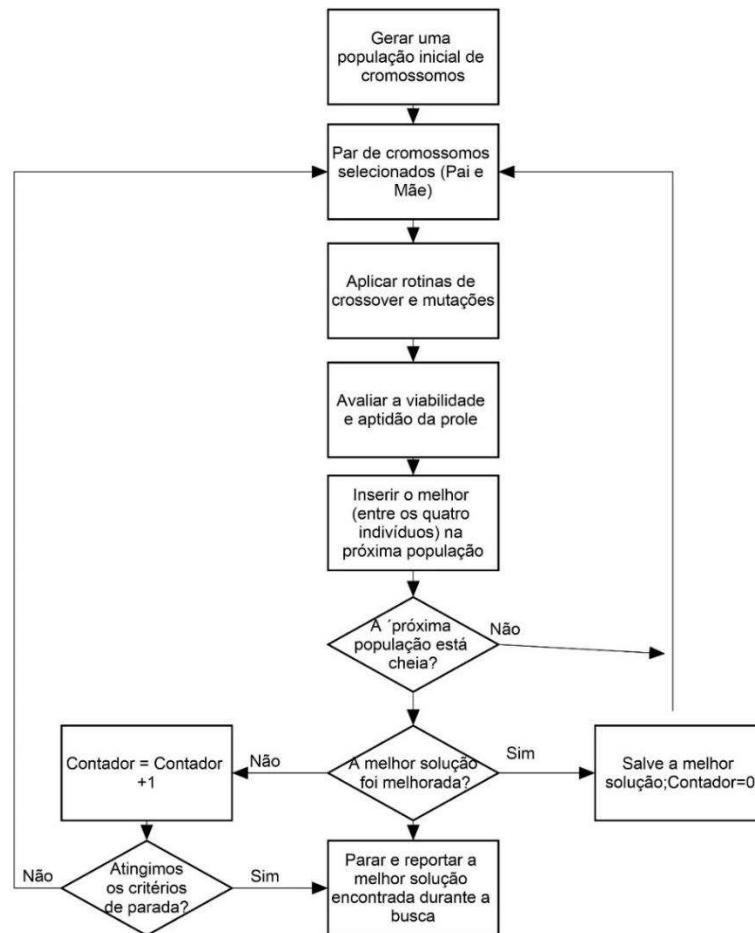


Figura 7 - Fluxograma do processo de busca do algoritmo AG. Adaptado de Bettinger et al. (2002).

Os parâmetros a serem otimizados no AG geralmente são representados em uma forma de string. Tais parâmetros e representação tem um grande impacto no desempenho do AG. Existem duas formas comuns de representar um problema de otimização com AG: um é o string binário, e um vetor com números inteiros ou reais. Os parâmetros de controle importantes incluem o tamanho da população (número de indivíduos na população), taxa de cruzamento e a taxa de mutação. Existem três operadores genéticos comuns: seleção, crossover e mutação. Um operador de reprodução adicional, inversão, algumas vezes também é utilizado. Alguns desses operadores, foram inspirados na natureza, sendo encontradas muitas versões dos mesmos. Não é necessário empregar todos esses operadores em um AG porque cada um funciona independentemente do outro (PHAM e KARABOGA, 2012).

De acordo com Gendreau e Potvin (2010), adaptado, um pseudocódigo para o AG é:

Algoritmo Genético em pseudocódigo:

Escolha uma população inicial de cromossomos

Enquanto o critério de parada não for atendido **faça**

Repita

Se condições de crossover forem atendidas **então**

{Escolha os cromossomos dos pais;

Escolha parâmetros de cruzamento;

Faça o cruzamento};

Se condições de mutação forem atendidas **então**

{Escolha os pontos de mutação;

Faça a mutação};

Avaliar a aptidão do cruzamento

Até criar filhos suficientes;

Selecione uma nova população;

Saída melhor solução encontrada.

Um passo importante do processo de seleção é reproduzir mais cópias dos indivíduos cujo valores da função de aptidão são maiores. Existem muitas formas para implementar a seleção e um método usual é o da seleção de roleta, proposta pela Holland (1975). A ideia básica da seleção de roleta é determinar a probabilidade de seleção para cada indivíduo de modo proporcional ao valor da função de aptidão. Portanto, a roleta é girada n vezes, onde n é o número de indivíduos na população. Em cada giro um indivíduo marcado pelo ponteiro da roleta é selecionado como pai para a próxima geração (SAKAWA, 2012). Os pais podem ser selecionados de acordo com sua aptidão por meio de uma das seguintes estratégias: seleção de roleta, amostragem estocástica universal (SUS), seleção de torneios, e seleção baseada em classificação (TALBI, 2009).

Alguns trabalhos já foram realizados utilizando o AG para resolução de problemas de regulação florestal. Rodrigues et al., (2004), testaram os efeitos do tamanho da população, do método de seleção e do tipo de crossover para o AG e concluíram que os melhores métodos de seleção foram os de Boltzmann e escalonamento e uma população ótima de 75 a 100 indivíduos, segundo os autores o tipo de crossover utilizado não influenciou o resultado. Silva et al., (2009), também avaliando os parâmetros de um AG para um problema de regulação florestal, concluíram que a população é o fator que mais influencia o desempenho do AG e a taxa de crossover e mutação não aumentaram o desempenho do algoritmo. Em outro trabalho realizado por Gomide et al., (2009), foram

avaliados os métodos de seleção torneio, elitista, roleta e bi-classista, sendo concluído que o melhor operador de seleção foi o de roleta.

Binoti et al., (2012), Binoti et al., (2014), utilizaram o AG para resolução de problemas de regulação florestal acrescentando restrições ambientais e sociais de caráter espaciais no modelo. Os parâmetros utilizados pelos autores foram, uma população de 30 indivíduos, seleção dos indivíduos por elitização, taxa de crossover de múltiplos pontos e uma taxa de mutação de 6%. O AG foi eficiente para resolver os modelos construídos.

2.2.2 – Enxame de partículas (OEP)

A otimização de enxames de partículas (OEP) é outra inspiradora meta-heurística estocástica baseada em populações, que imita o comportamento social dos organismos naturais como o acasalamento de pássaros e a escolarização de peixes para encontrar um lugar com comida suficiente. Originalmente, OEP foi projetada com sucesso para problemas de otimização contínua (BONABEAU et al., 1999; TALBI, 2009). A primeira aplicação foi proposta por Russell Eberhart e James Kennedy (1995), avaliando a meta-heurística para treinamento de redes neurais e aprendizado de robôs.

A OEP é um método simples, em que conceitos e paradigmas são implementados em algumas linhas de código de computador. Requer apenas operadores primitivos de matemática e é computacionalmente baixo tanto em termos de requisitos de memória quanto de velocidade (EBERHART e KENNEDY, 1995).

De acordo com Talbi (2009), uma partícula é composta por três vetores: o vetor x , que registra a posição atual (localização) da partícula no espaço de pesquisa, o vetor p , que registra a localização da melhor solução encontrada até este momento pela partícula, o vetor v contém um gradiente (direção) para o qual a partícula viajará sem perturbações. Além dos três vetores, dois valores de aptidão: o x -fitness registra a aptidão do vetor x , e o p -fitness registra a aptidão do vetor p .

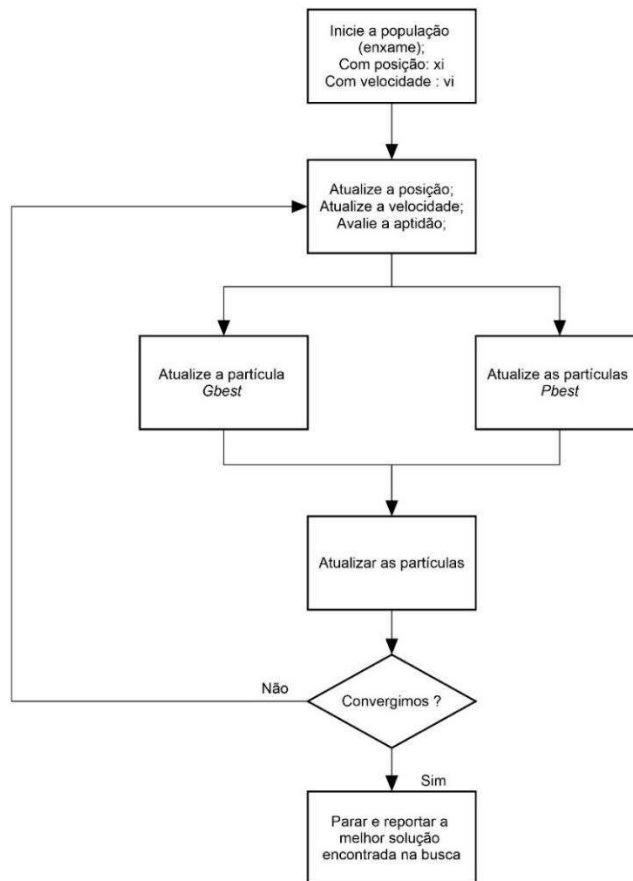


Figura 8 - Fluxograma do processo de busca do algoritmo Enxame de partículas. Adaptado de Lien e Cheng (2012).

Uma vizinhança deve ser definida para cada partícula, para denotar a influência social entre as partículas. São muitas as possibilidades de definir essa vizinhança. Tradicionalmente, dois métodos são utilizados: o método gbest, pelo qual a vizinhança é definida com todo conjunto de partículas e o método lbest, que é o melhor método local, pelo qual uma topologia é associada ao enxame. Por isso, a vizinhança de uma partícula é o conjunto de conexões diretamente conectadas as partículas. Além disso um enxame de partículas pode ser visto como um autômato celular onde células individuais (partículas em OEP) são atualizadas em paralelo, cada novo valor de célula depende apenas do valor antigo da célula e de sua vizinhança e todas as células são atualizadas usando as mesmas regras (TALBI, 2009).

Existem algumas operações comuns utilizados pelo OEP. A atualização da velocidade permite definir a quantidade de mudança que será aplicada a partícula e é definida por:

$$v_i(t) = w \times v_i(t - 1) + \rho_1 C_1 (p_1 - x_i(t - 1)) + \rho_2 C_2 (p_g - x_i(t - 1))$$

em que:

v_i = velocidade da partícula i , limitado a $[-V_{max}, +V_{max}]$;

w = a inércia que controla o impacto da velocidade anterior na atual;

ρ_1 e ρ_2 são duas variáveis aleatórias entre $[0, 1]$;

C_1 e C_2 constantes que representam os fatores de aprendizagem. O parâmetro C_1 é o fator cognitivo de aprendizagem, que representa a atração que uma partícula tem para seu próprio sucesso. O parâmetro C_2 é o aprendizado social, fator que representa a atração que uma partícula tem para o sucesso de seus vizinhos. A velocidade define a direção e a distância que a partícula deve ir.

Outra operação utilizada é a atualização da posição definida assim:

$$x_i(t) = x_i(t - 1) + v_i(t)$$

em que:

$x_i(t)$ = Posição da partícula i na posição t ; $x_i(t - 1)$ = Posição da partícula i , na posição $t-1$; $v_i(t)$ = velocidade da partícula i , na posição t .

A próxima operação é atualizar as melhores partículas encontradas: cada partícula atualizará (potencialmente) a melhor solução local: Se $f(x_i) \leq pbest_i$, então $p_i = x_i$, além disso, a melhor solução global do enxame é atualizada: Se $f(x_i) \leq gbest$, então $g_i = x_i$. Assim, em cada iteração, cada partícula mudará sua posição de acordo com sua própria experiência e a de partículas vizinhas. Conforme Talbi (2009), o algoritmo 6 apresenta o modelo de um algoritmo de enxame de partículas básico.

Algoritmo Enxame de partículas em pseudocódigo:

Inicialização aleatória de todo o enxame;

Repita

Avalie $f(x_i)$;

Para todas as partículas i

Atualize a velocidade:

$$v_i(t) = w \times v_i(t - 1) + \rho_1 C_1 (p_i - x_i(t - 1)) + \rho_2 C_2 (g - x_i(t - 1));$$

Mova para a próxima posição: $x_i(t) = x_i(t - 1) + v_i(t)$;

Se $f(x_i) \leq pbest_i$, **então** $pbest_i = x_i$;

Se $f(x_i) \leq gbest$, **então** $gbest = x_i$;

Atualize (x_i, v_i) ;

Terminar para;

Até critério de parada;

Saída melhor solução encontrada;

Fim;

Os parâmetros da OEP podem ser inicializados de forma dinâmica ou adaptável, para lidar com o trade-off entre intensificação e diversificação, durante a pesquisa. O número de partículas pode variar durante a pesquisa. Por exemplo, uma partícula pode ser removida quando seu desempenho é o pior (TALBI, 2009).

2.2.3 – Colônia de formigas (ACO)

A ideia básica em algoritmos de otimização de colônias de formigas (ACO) é imitar o comportamento cooperativo de formigas reais, para resolver problemas de otimização. A meta-heurística ACO surgiu no início da década de 90, Dorigo et al. (1999), como uma abordagem multi-agente, sendo que sua primeira aplicação foi para resolução do problema do caixeiro viajante.

Os algoritmos de formigas (Figura 9) foram inspirados pela observação de colônias de formigas reais. As formigas são insetos sociais, isto é, insetos que vivem em colônias e cujo comportamento é dirigido para a sobrevivência da colônia como um todo, com alto nível de estruturação (DORIGO et al., 1999). A fonte inspiradora do ACO é o comportamento de forrageamento das formigas reais. Ao procurar matéria vegetal para produção de fungos, as formigas exploram inicialmente a área que rodeia seu ninho, de forma aleatória. Assim que uma formiga encontra uma fonte de matéria vegetal, avalia a quantidade e a qualidade e carrega parte de volta ao ninho. Durante a viagem de regresso, a formiga deposita uma trilha de feromônio no chão. A quantidade de feromônio depositada, que depende da quantidade e qualidade da matéria vegetal, guia outras formigas à fonte de matéria vegetal (DORIGO e BLUM, 2005).

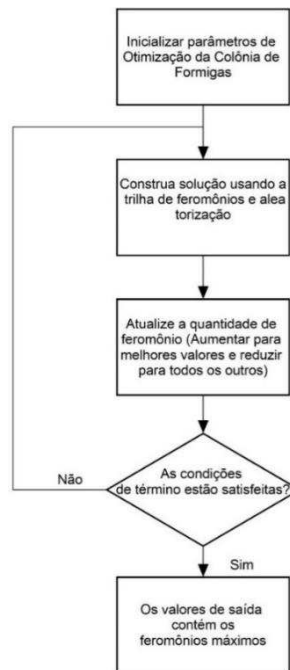


Figura 9 - Fluxograma do processo de busca do algoritmo colônia de formigas. Adaptado de Kaveh e Talatahari (2009).

Um algoritmo ACO é um processo iterativo onde a informação de feromônio é transferida de uma iteração para a próxima. O processo continua até que algum critério de parada seja cumprido (MERKLE e MIDDENDORF, 2014). Conforme esses autores, um modelo de um algoritmo básico de ACO é:

Algoritmo colônia de formigas em pseudocódigo:

Inicialize valores de feromônio

Repetir

Para

formiga $k \in \{1, \dots, M\}$;

Construir uma solução;

Final

Para todos os valores de feromônio;

Diminua o valor por uma certa porcentagem {evaporação};

Fim

Para todos os valores de feromônio correspondentes a boas soluções;

Faz

Aumentar o valor {intensificação};

Fim

Até critério de parada ;

Saída melhor solução encontrada;

Fim;

O algoritmo é composto principalmente de duas etapas iteradas: Construção de soluções e atualização de feromônio.

As formigas artificiais podem ser consideradas procedimentos gananciosos estocásticos que constroem uma solução de forma probabilística, adicionando componentes de solução parciais até que uma solução completa seja encontrada (TALBI, 2009). Conforme o autor, este processo iterativo leva em consideração os seguintes itens: as trilhas de feromônio, memorizam as características de "boas" soluções geradas, quando a construção de novas soluções pelas formigas, as trilhas de feromônio mudam dinamicamente durante a pesquisa para refletir o conhecimento adquirido e representa a memória de toda a formiga no processo de busca, informação heurística dependente do problema: uma informação específica do problema dá mais dicas às formigas em suas decisões para construir soluções.

A atualização de feromônio é feita usando as soluções geradas, utilizando uma regra de atualização de feromônio global e aplicada em duas fases, (evaporação e reforço). Na fase de evaporação em que a trilha do feromônio diminui automaticamente. Cada valor do feromônio é reduzido por uma proporção fixa:

$$\tau_{ij} = (1 - \rho)\tau_{ij} \quad \forall i, j \in [1, n]$$

em que: τ_{ij} = valor do feromônio; n = número de formigas; ρ $[0,1]$, representando a taxa de redução do feromônio. O objetivo da evaporação é evitar para todas as formigas uma convergência prematura através de boas soluções e encorajar a diversificação no espaço de busca. Na fase de reforço a trilha de feromônio é atualizada para as soluções geradas. A abordagem mais utilizada é a atualização off-line de feromônio, aplicada de uma única vez a todas as formigas gerando uma solução completa (TALBI, 2009).

2.3 - Outras meta-heurísticas

Outras meta-heurísticas populacionais inspiradas na natureza, como colônia de abelhas e sistemas imunológicos artificiais podem ser usadas para resolução de problemas complexos de otimização. O algoritmo baseado em otimização de colônia de abelhas é uma meta-heurística estocástica que pertence à classe de algoritmos de inteligência de enxame. Os algoritmos são inspirados pelo comportamento de uma colônia de abelhas que exibe muitos recursos que podem ser usados como modelos de comportamento inteligente e coletivo. Esses recursos incluem a exploração de néctar, o acasalamento

durante o voo, o forrageamento de alimentos, a dança do zangão e divisão de trabalho (TALBI, 2009).

Recentemente tem se dado atenção aos sistemas imunológicos para o desenvolvimento de novos algoritmos de otimização. Os processos biológicos que são simulados para desenvolver algoritmos de sistemas imunológicos incluem: reconhecimento de padrão, seleção clonal para células B, seleção negativa de células T, Afinidade de maturação, teoria do perigo e teoria da rede imune (TALBI, 2009).

3 - Aplicações de meta-heurísticas no planejamento florestal hierárquico.

Os planos de manejo florestal são frequentemente desenvolvidos para ajudar a processar conflitos que surgem entre um número desejado de bens e serviços na sociedade e, mais especificamente, para organizar o tempo e a sequência de atividades de manejo florestal (BETTINGER et al., 2015). Os planos de manejo podem ser estabelecidos nos níveis estratégicos (longo prazo), tático (médio prazo) e operacional (curto prazo).

Durante muitos anos, o planejamento florestal estratégico (PFE), foi direcionado para maximização das receitas, sem levar em conta restrições de ordem ambiental e social. Isto tem mudado nos últimos anos, com a inclusão dessas restrições (BINOTI et al., 2012; BINOTI et al., 2014; GOMIDE et al., 2013).

A modelagem do problema de PFE é realizada tradicionalmente utilizando programação linear (PL), programação linear inteira (PIM) ou programação linear inteira mista (PIM). Na maioria das vezes os modelos são resolvidos por métodos exatos, simplex (PL) e Branch and bound (PLI, PIM), em tempo exequível. Porém, o PFE tem se tornado cada vez mais complexos, devido a necessidade de acrescentar objetivos espaciais conflitantes, como o manejo de fauna, paisagem, prevenção contraventos e fogos e incertezas inerentes ao problema que eram negligenciadas. Assim, o problema passa a ter um grau de complexidade elevado, sendo os métodos exatos, portanto, ineficientes para encontrar uma solução ótima em tempo hábil (BINOTI et al., 2014).

Uma alternativa para solucionar problemas de PFE são os algoritmos aproximativos, especificamente as meta-heurísticas, que são utilizadas para resolver problemas de otimização combinatória. Estes algoritmos têm com vantagem ser genéricos, de fácil implementação, podendo ser aplicados a muitos problemas de otimização (BINOTI et al., 2012).

Nos últimos anos o uso de meta-heurísticas no setor florestal tem sido mais intenso, devido principalmente a inclusão de restrições conflitantes e de elevada complexidade nos problemas encontrados pelos gestores florestais. São encontradas aplicações em planejamento florestal estratégico (RODRIGUES et al., 2003; RODRIGUES et al., 2004), planejamento florestal estratégico com restrições espaciais (BINOTI et al., 2012; ÖHMAN, 2000; BOSTON e BETTINGER, 2001), problemas do de transporte (LIN et al., 2016), otimização de sequência de desbastes (MORIGUCHI et al., 2017), localização de máquinas de colheita florestal (LEGÜES et al., 2007), programação de colheita com restrições de adjacência (LOCKWOOD e MOORE, 1993; BETTINGER e BOSTON e SESSIONS, 1999). Na maioria destes problemas as meta-heurísticas têm gerado boas soluções.

Para facilitar o resumo das principais aplicações de meta-heurísticas no planejamento florestal hierárquico foi elaborada a Tabela 3, onde são apresentados, cronologicamente, alguns dos principais casos de uso de meta-heurísticas em planejamento florestal. Verifica-se que na maioria dos estudos os autores chegaram a conclusão da mesma ordem em termos de eficiência da meta-heurística utilizada. Isto tem uma certa lógica, uma vez que características desejáveis das meta-heurísticas são a capacidade de generalização aos problemas de natureza combinatória, a simplicidade, o baixo custo computacional e a flexibilidade.

A Tabela 2 foi organizada para auxiliar na análise das referências bibliográficas, apresentadas na Tabela 3. Até a data do estudo as meta-heurísticas mais utilizadas para solucionar problemas de planejamento florestal foram as meta-heurísticas, Simulated annealing, Busca tabu, Algoritmo genético, híbrida de Algoritmo genético e Busca tabu e os Autômatos celulares (Tabela 2). As meta-heurísticas Raindrop, Scatter search, Colônia de formigas, enxame de partículas e Grasp são de uso mais recente e também tem conduzido a boas soluções para os problemas analisados (NASCIMENTO et al., 2012; LIN et al., 2016; HERNADEZ et al., 2014; MEIGNAN et al., 2012).

Tabela 2 - Principais meta-heurísticas e quantidade de casos de uso contemplados no presente estudo.

Meta-heurísticas	Obs.
Algoritmo Cultural/EA	1
Algoritmo Genético/EA	9
Autômatos Celulares	3
Busca Tabu	9
Busca Tabu, Algoritmo Genético	1
Busca Tabu, Simulated Annealing	2
Colônia de formigas	2
Diversas	8
Enxame de partículas (EPO)	1
GRASP	1
Hybrid Busca Tabu/Algoritmo Genético	3
Hybrid Busca Tabu/Threshold accepting	1
ISA	1
Raindrop	2
Random Search	1
RazãoR	1
Scatter Search/EA	2
Self-organization/EA	1
Simulated Annealing	26
Threshold accepting	1
Total Geral	76

Como um resumo das aplicações da meta-heurística Simulated annealing, os trabalhos de Lockwood e Moore (1993), Dahlin e Sallnäs (1993), Crowe e Nelson (2003) e Gomide et al. (2013), utilizaram a SA para realizar o agendamento da colheita envolvendo restrições de adjacência. Öhman e Eriksson (1998), Öhman (2000), Öhman e Eriksson (2002), Öhman e Låmas (2005), definiram áreas centrais de florestas mais velhas no planejamento florestal estratégico. Baskent e Jordan (2002), utilizando a meta-heurística SA para fazer o manejo da paisagem no planejamento florestal, sendo possível acomodar vários objetivos conflitantes. Öhman e Låmas (2003), realizaram o agrupamento de blocos de colheita com uma abordagem multiobjetivo. Heinonen et al. (2009), González-Olabarria e Pukkala (2011), Heinonen et al. (2011), utilizaram a SA para análise contra riscos de vento e fogo no planejamento florestal. Moriguchi et al. (2015), Moriguchi et al. (2017), para determinar o regime ótimo de desbastes, Lin et al. (2017), consideraram as emissões e o sequestro de carbono no planejamento florestal.

Nos últimos anos alguns trabalhos tem surgido com avaliação de novas abordagens para a meta-heurística Simulated Annealing: Strimbu e Paun (2012), avaliaram a

sensibilidade do planejamento florestal aos parâmetros da SA e Borges et al. (2014a), Borges et al. (2014b), Dong et al. (2015) e Dong et al. (2017), compararam técnicas de busca de vizinhança gerando grande melhoria nas técnicas de busca para a SA. Nestes trabalhos cabe destacar a palavra flexibilidade, muito utilizada para descrever a qualidade e o motivo do uso da SA.

Outra meta-heurística muito utilizada para solucionar problemas de planejamento florestal é o Algoritmo Genético (AG), Lu e Eriksson (2000), utilizaram esta meta-heurística para avaliar os benefícios da formação de blocos de colheitas no planejamento operacional, Binoti et al. (2012), Binoti et al. (2014), para realizar a regulação de florestas equiâneas, com restrições de adjacência e Thompson et al. (2009) avaliaram estratégias de penalidade para o AG. Além desses trabalhos Ducheyne et al. (2004) e Fotakis et al. (2012), apresentaram uma abordagem multiobjetivo para o AG.

Alguns trabalhos surgiram com o intuito de avaliar e comparar as meta-heurísticas, Pukkala e Kurttila (2005), comparam seis meta-heurísticas para problemas difíceis de planejamento florestal e concluíram que, com os parâmetros ajustados corretamente, os métodos não diferem em termos do valor da função de avaliação, sendo coerente uma vez que foram utilizadas técnicas amplamente utilizadas e aceitas. Bettinger et al. (2002), avaliaram oito meta-heurísticas para resolver difíceis problemas de planejamento, os autores comentam que cada método exige uma certa habilidade e criatividade do programador para fazer uma meta-heurística complexa ser executada bem e rápido.

Tabela 3 – Resumo das principais referências com utilização de meta-heurísticas no planejamento florestal hierárquico.

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
1990	Comparison of a random search algorithm and mixed integer programming for solving area-based forest plans.	RS	Nelson, J.; Brodie, J.D.	Acreditamos que o MCIP é uma técnica eficaz para gerar soluções aceitáveis para problemas de planejamento baseados em áreas.	Planejamento Florestal/Tático/Espacial
1993	Harvest scheduling with spatial constraints: a simulated annealing approach	SA	Lockwood, C.; Moore, T.	O algoritmo SA foi capaz de gerar soluções que obedeciam às restrições espaciais: os blocos de colheita adjacentes não foram colhidos dentro de um período de exclusão declarado e todas as áreas de bloco de colheita contínua estavam dentro de uma faixa de tamanho aceitável.	Planejamento Florestal/Tático/Espacial
1993	Harvest scheduling under adjacency constraints - a case study from the Swedish sub-alpine region	SA, RS	Dahlin, B.; Sallnäs, O.	Pode-se concluir que o algoritmo SA é um método interessante para o agendamento de colheita envolvendo restrições de adjacência.	Planejamento Florestal/Tático/Espacial
1995	Heuristic solution approaches to operational forest planning problems.	BT, SA, IC	Murray, A. T.; Church, R. L.	BT, SA, IC, são todas abordagens de soluções viáveis para o problema operacional de planejamento florestal e analisando a solução final os resultados são muito encorajadores.	Planejamento Florestal/Operacional/Estradas
1997	Using tabu search to schedule timber harvests subject to spatial wildlife goals for big game	BT	Bettinger, P.; Sessions, J. ;Boston, K.	Em conclusão, demonstrámos que um algoritmo de BT pode ser desenvolvido para atingir simultaneamente as metas espaciais da vida selvagem com cada escolha de decisão com a metodologia de planejamento florestal.	Planejamento Florestal/Tático/Espacial
1998	A tabu search algorithm for finding good forest harvest schedules satisfying green-up constraints	BT	Brumelle, S.; Granot, D.; Halme, M. ; Vertinsky, I.	A BT que desenvolvemos fornece os inputs ao sistema de suporte e decisão, gerando "bons" planos de colheita para avaliação.	Planejamento Florestal/Tático/Espacial
1998	The core area concept in forming contiguous areas for long-term forest planning	SA	Öhman, K. ; Eriksson, L.O.	Concluimos que o conceito de área central pode ser usado para criar áreas contíguas de crescimento de florestas antigas em planejamento de longo prazo.	Planejamento Florestal/Estratégico/Espacial
1999	Intensifying a heuristic forest harvest scheduling search procedure with 2-opt decision choices	BT	Bettinger, P.; Boston, K.; Sessions, J.	O uso da busca local 2-opt para mudar simultaneamente o momento da colheita duas unidades terrestres podem fornecer melhores soluções para problemas que incluem restrições de fluxo uniforme e adjacência.	Planejamento Florestal/Tático/Espacial

Obs: Veja legenda no final da Tabela, na página 39.

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
1999	An analysis of Monte Carlo integer programming, simulated annealing, and tabu search heuristics for solving spatial harvest scheduling problems.	MC, SA, BT	Boston, K.; Bettinger, P.	As melhores soluções encontradas utilizando a BT foram 93.7% da solução ótima, e as melhores soluções encontradas utilizando SA foram 96.5% da solução ótima.	Planejamento Florestal/Tático/Espacial
2000	Formation of harvest units with genetic algorithms	AG/E	Lu, F.; Eriksson, L.O.	Em resumo, parece que AG é capaz de formar blocos de colheita adequado.	Planejamento Florestal/Operacional/Espacial
2000	A model and tabu search method to optimize stand harvest and road construction schedules.	BT	Richards, W.; Gunn, A.,	Este problema, que tem uma estrutura de restrição complexa, foi abordado com sucesso usando métodos de gráfico para lidar com aberturas e um método heurístico eficiente para calcular as redes rodoviárias quase ótimas.	Planejamento Florestal/Tático/Espacial
2000	A target-oriented approach to forest ecosystem design—changing the rules of forest planning	SA	Liu, G.; Nelson, J.D.; Wardman, C.W.	Abordagens adaptativas e flexíveis como FSOS ajudam a mudar a forma como prevemos desenvolvimento de ecossistemas e paisagens com o gerenciamento integrado de recursos.	Planejamento Florestal/Estratégico/Espacial
2000	Creating continuous areas of old forest in long-term forest planning	SA	Öhman, K.	Pode-se concluir que é possível incluir a espacialidade em planejamento florestal de longo prazo.	Planejamento Florestal/Estratégico/Espacial
2001	Development of spatially feasible forest plans: a comparison of two modeling approaches.	Hy (BT, AG/E)	Boston, K.; Bettinger, P.	Como resultado, uma abordagem de dois estágios (LP e heurística) parece, a menos com este problema, para produzir mais eficiência planos de floresta espacialmente viáveis do que um estágio único abordagem.	Planejamento Florestal/Estratégico/Espacial
2001	The economic impact of green-up constraints in the southeastern United States.	Hy (BT, AG/E)	Boston, K.; Bettinger, P.,	Em relação à heurística que usamos para gerar soluções para esses problemas de planejamento florestal, sentimos que a BT híbrido com o método de AG pode produzir melhor resultados que uma técnica de pesquisa tabu tradicional.	Planejamento Florestal/Tático/Espacial
2002	Combining tabu search and genetic algorithm heuristic techniques to solve spatial harvest scheduling problems	BT, AG/E	Boston, K.; Bettinger, P.	As heurísticas aqui descritas são tentativas iniciais de combinar algumas características desejáveis (intensificação, diversificação) da BT e do AG para criar um Técnica heurística híbrida.	Planejamento Tático/Colheita/Espacial

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2002	Forest landscape management modeling using simulated annealing	SA	Baskent, E.Z.; Jordan, G.A.,	SA demonstrou através de um estudo de caso que é possível acomodar vários objetivos da floresta. Os objetivos são definidos e formulados por unidades comuns não monetárias que utilizam funções de penalização de custos.	Planejamento Florestal/Tático/Espacial
2002	Allowing for spatial consideration in long-term forest planning by linking linear programming with simulated annealing	SA	Öhman, K.; Eriksson, L.O.	Concluímos que uma possível maneira de incluir a consideração espacial no plano florestal de longo prazo é combinar SA com LP em um método de solução coerente.	Planejamento Florestal/Estratégico/Espacial
2002	Eight heuristic planning techniques applied to three increasingly difficult wildlife planning problems	SA, BT, AG, GD, TA, Hy (BT,AG/E)	Bettinger, P., Sessions, J., Chung, W., Graetz, D.; Boston.	O objetivo final do uso de técnicas heurísticas é produzir soluções de alta qualidade em pequenas quantidades de tempo para problemas com não-linearidades ou relacionamentos combinatórios	Planejamento Florestal/Estratégico/Espacial
2003	A 2-opt tabu search procedure for the multiperiod forest harvesting problem with adjacency, greenup, old growth, and even flow constraints	BT	Caro, F.; Constantino, M.; Martins, I.; Weintraub, A.	As conclusões são satisfatórias, no sentido de que o procedimento proposto encontrou boas soluções em tempos razoáveis para problemas de grande escala que seriam impossíveis de resolver usando métodos exatos atuais baseados em técnicas de programação linear.	Planejamento Florestal/Tático/Espacial
2003	Tabu search design for difficult forest management optimization problems	BT	Richards, E.W.; Gunn, E.A.	Para resumir, escolhendo uma boa estratégia de memória de curto prazo, alisamento os espaços de pesquisa e diversificação são fatores de design importantes para esse problema.	Planejamento Florestal/Tático/Espacial
2003	Solução de problemas de planejamento florestal com restrições de inteireza utilizando busca tabu	BT	Rodrigues, F. L.; Leite, H. G.; Santos, H. N.; Souza, A. L.	Algumas configurações de parâmetros propiciaram melhor eficácia para a BT. A permanência dinâmica foi uma boa estratégia para melhorar a eficácia da BT, pois apresentou resultados semelhantes aos melhores valores de permanência estática.	Planejamento Florestal/Estratégico
2003	An indirect search algorithm for harvest-scheduling under adjacency constraints.	ISA	Crowe, K.; Nelson, J.	Seria imprudente concluir que a ISA é superior à BT ou SA na resolução de problemas da programação da colheita	Planejamento Florestal/Tático/Espacial
2003	Clustering of harvest activities in multi-objective long-term forest planning.	SA	Öhman, K.; Lämås, T.,	Os resultados do estudo de caso indicam que o método selecionado é uma escolha conveniente tanto para encontrar soluções próximas quanto otimizadas e pelo tempo relativamente curto.	Planejamento Florestal/Estratégico/Espacial

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2003	Spatial forest plan development with ecological and economic goals.	TA	Bettinger, P.; Johnson, D.L.; Johnson, K.N.	Este processo de planejamento de floresta espacial utilizando heurística permite aos gestores florestais examinar uma série de opções de gestão, tanto das perspectivas econômicas como ecológicas.	Planejamento Florestal/Estratégico/Espacial
2004	Single versus multiple objective genetic algorithms for solving the even-flow forest management problem.	AG/E	Ducheyne, E.; De Wulf, R.R.; De Baets, B.	Ambas as abordagens mostram que o AG de múltiplos objetivos tem melhor desempenho em termos de eficiência.	Planejamento Florestal/Tático/Espacial
2004	Meta-heurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade	AG/E	Rodrigues, F.L.; Leite, H.G.; Santos, H.D.N.; Souza, A.L.D.; Silva, G.F.D.	Os melhores métodos de seleção foram os de Boltzmann e escalonamento, e os melhores tamanhos de população foram iguais a 75 e 100 indivíduos.	Planejamento Florestal/Estratégico
2004	A comparison of one-and two-compartment neighbourhoods in heuristic search with spatial forest management goals	RA, HO, SA, BT	Heinonen, T.; Pukkala, T.	Dos quatro métodos testados, o SA e BT foram os melhores.	Planejamento Florestal/Tático/Espacial
2004	Meta-heurística Simulated Annealing para solução de problemas de planejamento florestal com restrições de integridade	SA	Rodrigues, F.L.; Leite, H.G.; Santos, H.D.N.; Souza, A.L.D.; Ribeiro, C.A.Á.S	Com base nos resultados deste trabalho, pôde-se concluir que a metaheurística SA é flexível por comportar restrições de diversas naturezas, sem a necessidade de alterar a estrutura do algoritmo adotado.	Planejamento Florestal/Estratégico
2005	Examining the performance of six heuristic optimisation techniques in different forest planning problems	RA, HO, SA, BT, Hy (SA, HO), AG/E	Pukkala, T.; Kurttila, M.	O resultado indica apenas que nenhum dos métodos é um completo fracasso. No entanto, algumas diferenças na qualidade das soluções podem ser encontradas.	Planejamento Florestal/Estratégico/Espacial
2005	An evaluation of the simulated annealing algorithm for solving the area-restricted harvest-scheduling model against optimal benchmarks	SA	Crowe, K.A.; Nelson, J.D.	Soluções ótimas em comparação com benchmarks ideais. Dos 29 casos resolvidos, o desvio médio do ótimo variou de aproximadamente 1% a 13% utilizando a SA.	Planejamento Florestal/Tático/Espacial
2005	Reducing forest fragmentation in long-term forest planning by using the shape index.	SA	Öhman, K.; Lämäs, T.	Nós podemos concluir que o Shape Index pode ser usado em planejamento de floresta a longo prazo como critério no modelo de otimização para diminuir a fragmentação da floresta antiga no panorama.	Planejamento Florestal/Estratégico/Espacial
2006	Optimisation algorithms for spatially constrained forest planning	AG/E, SA, HC	Liu, G.; Han, S.; Zhao, X.; Nelson, J.D.; Wang, H.; Wang, W.	Nessa pesquisa, descobrimos que o algoritmo de SA é mais eficiente do que o AG para os problemas de agendamento da colheita florestal.	Planejamento Florestal/Tático/Espacial

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2006	A new heuristic method for solving spatially constrained forest planning problems based on mitigation of infeasibilities radiating outward from a forced choice	BT, RD, TA	Bettinger, P.; Zhu, J.	Contudo, O que resta ser visto é se o novo método pode ser aplicado com sucesso ao mais amplo variedade de problemas de pesquisa operacional em silvicultura e outros campos.	Planejamento Florestal/Tático/Espacial
2006	An economic and landscape evaluation of the green-up rules for California, Oregon, and Washington (USA).	Hy (BT, AG/E)	Boston, K.; Bettinger, P.	As restrições de green-up contidas no Oregon e regras de práticas florestais estaduais de Washington ambos produzidas os retornos econômicos significativamente diferentes.	Planejamento Florestal/Tático/Espacial
2006	Optimizing heuristic search in forest planning.	SA, BT, TA	Pukkala, T.; Heinonen, T.	A principal contribuição do estudo foi mostrar uma técnica razoavelmente simples para aliviar um passo muito tedioso de uso prático da busca heurística no planejamento florestal.	Planejamento Florestal/Tático/Espacial
2007	The use of cellular automaton approach in forest planning	AC	Heinonen, T.; Pukkala, T.	A hipótese que o método baseado em AC é capaz de produzir soluções de alta qualidade com modesto custo computacional é comprovada com os resultados.	Planejamento Florestal/Tático/Espacial
2007	Forest planning using co-evolutionary cellular automata	AC	Mathey, A.H.; Krcmar, E.; Tait, D.; Vertinsky, I.; Innes, J.,	O algoritmo baseado em AC que foi desenvolvido neste artigo estima com sucesso alguns valores florestais e sua sustentabilidade a longo prazo e parece adequada como uma ferramenta para o planejamento florestal a longo prazo.	Planejamento Florestal/Estratégico/Espacial
2007	Application of ant colony optimization for the risk management of wind damage in forest planning	ACO, AG/E, SA	Zeng, H.; Pukkala, T.; Peltola, H.; Kellomaki, S.	Em conclusão, a otimização revisada da ACO pode ser aplicado no planejamento florestal para resolver problemas combinatórios, uma vez que realiza logicamente, produz resultados razoáveis e é comparável a outras heurísticas.	Planejamento Florestal/Espacial/Risco de Ventos
2007	Landscape-level optimization using tabu search and stand density-related forest management prescriptions	BT	Bettinger, P.; Boston, K.; Kim, Y.H.; Zhu, J.,	Nós mostramos que o movimento um 1-opt na BT permite o desenvolvimento de planos florestais para grandes áreas com complexos objetivos. No entanto, melhorar o processo 2-opt move melhora a qualidade dos planos florestais.	Planejamento Florestal/Estratégico/Espacial
2007	A tabu search approach for solving a difficult forest harvesting machine location problem	BT	Legües, A.D.; Ferland, J.A.; Ribeiro, C.C.; Vera, J.R.; Weintraub, A.	Estes resultados promissores usando a meta-heurística BT têm aplicações práticas, com esta abordagem podem ser implementadas sistemas existentes de localização de máquinas utilizadas pelas empresas florestais	Planejamento Florestal/Operacional/Espacial
2007	Additional insight into the performance of a new heuristic for solving spatially constrained forest planning problems.	RD, BT, TA	Zhu, J.; Bettinger, P.; Li, R.	Pode-se concluir a partir deste trabalho que pode ser vantajoso usar essa heurística para problemas com restrições espaciais e de planejamento florestal e problemas que não envolve jovens distribuições de classe de idade inicial.	Planejamento Florestal/Tático/Espacial

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2007	The use of heuristic optimization in risk management of wind damage in forest planning	SA, BT, AG/E	Zeng, H.; Pukkala, T.; Peltola, H.	As três técnicas heurísticas produzem resultados bastante similares para todos os problemas de planejamento. No entanto, a BT foi encontrada um melhor desempenho do que SA e AG no Problema 4.	Planejamento Florestal/Espacial/Risco de Ventos
2008	An object-oriented cellular automata model for forest planning problems	AC	Mathey, A.H.; Krcmar E.; Dragicevic S.; Vertinsky, I.	A natureza descentralizada dos modelos dos AC permite levar em consideração um grande número de detalhes do local (condições da unidade de manejo, planejamentos potenciais), enquanto a implementação orientada permite uma rápida computação das regras de transição.	Planejamento Florestal/Estratégico/Espacial
2008	Estimating the effects of adjacency and green-up constraints on landowners of different sizes and spatial arrangements located in the southeastern US	Hy (BT, TA)	Zhu, J.; Bettinger, P.	Que pequenos proprietários de terras e proprietários de terras as novas distribuições de classes iniciais seriam mais afetadas por uma adjacência típica e política green-up americana.	Planejamento Florestal/Tático/Espacial
2009	Uso do algoritmo genético no planejamento florestal considerando seus operadores de seleção	AG/E	Gomide, L. R.; Arce, J. E.; Da Silva, A. C. L.	Os métodos de seleção mais eficientes foram os métodos menos eficazes, ao considerar as médias dos fitness como critério de comparação.	Planejamento Florestal/Estratégico
2009	Metaheurística algoritmo genético na solução de modelos de planejamento florestal.	AG/E	Silva, G. F.; Piassi, L. C.; Mõra, R.; Martins, L. T.; Teixeira, A. F.; Barros Junior, A. A.	A população inicial (Pini) é o fator que mais influencia o desempenho do AG em termos de distância, de modo que, quanto maior o Pini, menor a distância da resposta obtida pelo AG da resposta exata.	Planejamento Florestal/Estratégico
2009	Selection and penalty strategies for genetic algorithms designed to solve spatial forest planning problems.	AG/E	Thompson, M.P.; Hamann, J.D.; Sessions, J	Apresentamos o design de um AG dinâmico para planejamento florestal orientado de forma espacial e demonstrou que o AG encontrou soluções viáveis de alta qualidade.	Planejamento Florestal/Tático/Espacial
2009	Integrating the risk of wind damage into forest planning.	SA	Heinonen, T.; Pukkala, T.; Ikonen, V.P.; Peltola, H.; Venäläinen, A.; Dupont, S.	O método integrado de avaliação de risco desenvolvido neste estudo mostrou grande potencial em termos de redução do risco de vento danos ao nível da paisagem.	Planejamento Florestal/Espacial/Risco de Ventos
2010	A incorporação de corredores de conectividade no manejo de florestas industriais utilizando a heurística da RazãoR	RR	Moreira, J.M.M.Á.P.;Rodriguez, L.C.E.,	A heurística foi eficaz e eficiente no número de iterações necessárias para encontrar medidas viáveis para o problema, mostrando-se ineficiente apenas no tempo computacional.	Planejamento Florestal/Estratégico/Espacial

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2010	Informed development of metaheuristics for spatial forest planning problems.	SA/TA/TS/RD	Li, R.; Bettinger, P.; Boston, K.	No entanto, sentimos que a nosso trabalho representa um avanço na exploração de métodos eficiente e eficazes para localizar soluções quase ótimas para problemas complexos de planejamento florestal.	Planejamento Florestal/Tático/Espacial
2011	Integrating fire risk considerations in landscape-level forest planning.	SA	González-Olabarria, J.R.; Pukkala, T.	Nosso estudo sugere que o planejamento do manejo florestal apropriado permite obter rendimentos razoáveis de gerenciamento de madeira comercial, ao mesmo tempo que usa gestão como uma estratégia de prevenção de fogo a longo prazo.	Planejamento Florestal/Estratégico/ Risco de fogo
2011	Consideration of strong winds, their directional distribution and snow loading in wind risk assessment related to landscape level forest planning.	SA	Heinonen, T.; Pukkala, T.; Ikonen, V.P.; Peltola, H.; Gregow, H.; Venäläinen, A.	Incorporar a direção do vento para cálculos de risco afeta o disposição da paisagem florestal resultante. É claramente mostrado neste estudo que, ao utilizar a otimização espacial, é possível ter um efeito sobre a estrutura da paisagem.	Planejamento Florestal/Espacial/Risco de Ventos
2011	A multiobjective model for forest planning with adjacency constraints.	SS/E	Gómez, T.; Hernández, M.; Molina, J.; León, M.A.; Aldana, E.; Caballero, R.	O método evolutivo da SSPMO foi selecionado devido à sua capacidade altamente competitiva de resolução de problemas multiobjectivos reais e devido à sua estrutura modular facilitando sua adaptação.	Planejamento Florestal/Tático/Espacial
2012	Regulation of even-aged forest with adjacency constraints	AG/E	Binoti, D.H.B.; Da Silva Binoti, M.L.M.; Leite, H.G.; Gleriani, J.M.; Campos, J.C.C.;	A aplicação da técnica AG foi eficiente para a resolução de modelos, construídos com restrições e objetivos socioeconômicos e caráter ambiental.	Planejamento Florestal/Estratégico/ Espacial
2012	Spatial genetic algorithm for multi-objective forest planning.	AG/E	Fotakis, D.G.; Sidiropoulos, E.; Myronidis, D.; Ioannou, K.	A abordagem atual melhora potencialmente o AG para problemas de ordenamento do território além do examinado neste artigo.	Planejamento Florestal/ M.O / Espacial
2012	A heuristic approach to automated forest road location.	GRASP	Meignan, D.; Frayret, J.M.; Pesant, G.; Blouin, M.	Finalmente, são geradas soluções de baixo custo em uma quantidade reduzida de tempo.	Planejamento Florestal/Operacional/Estradas
2012	Uso da Meta-Heurística otimização por exame de partículas no planejamento florestal.	EPO	Nascimento, F. A. F. D.; Dias, A. N.; Figueiredo Filho, A.; Arce, J. E.; Miranda, G. D. M.	O algoritmo EPO pode ser aplicado na resolução de problemas de planejamento florestal com variáveis inteiras, tendo desempenho semelhante ao de outras meta-heurísticas encontradas na literatura.	Planejamento Florestal/Estratégico

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2012	Comparison of effectiveness of different implementations of a heuristic forest harvest scheduling search procedure with different number of decision choices simultaneously changed per move	SA	Garcia-Gonzalo, J.; Borges, J.G.; Hilebrand, W.; Palma, J.	Os resultados preliminares indicam que, para todas as temperaturas iniciais e taxas de decréscimo alterar 1-opt move alcança mais rápido e melhores resultados do que mudar 3-opt move.	Planejamento Florestal/Tático/Espacial
2012	Sensitivity of forest plan value to parameters of simulated annealing	SA	Strimbu, B.M.; Paun, M.,	A seleção dos parâmetros iniciais da SA pode aumentar a capacidade de produzir resultados rápidos se a gama de valores possíveis para temperatura inicial, taxa de recozimento e número de corridas forem cuidadosamente escolhidos.	Planejamento Florestal/Tático/Espacial
2013	Comparação entre a meta-heurística simulated annealing e a programação linear inteira no agendamento da colheita florestal com restrições de adjacência.	SA	Gomide, L.R.; Arce, J.E.; Da Silva, A.C.L.	A meta-heurística SA é capaz de resolver problemas envolvendo o agendamento da colheita florestal com restrições espaciais, no qual apresenta um tempo computacional inferior ao consumido pela PLI.	Planejamento Florestal/Estratégico/Espacial
2014	Regulação de florestas equiâneas com restrição de classes de idade por compartimento	AG/E	Binoti, D.H.B.; Binoti, M.L.M.D.S.; Leite, H.G.; Gleriani, J.M.; Oliveira, M.L.R.D.; Campos, J.C.C.; Souza, A.L.D.; Ribeiro, C.A.Á.S.	A metodologia proposta apresenta efeito benéfico para o manejo da paisagem podendo ser utilizada em modelos de planejamento florestal.	Planejamento Florestal/Estratégico/Espacial
2014	Adjacency constraints in forestry-A simulated annealing approach comparing different candidate solution generators.	SA	Borges, P.; Bergseng, E.; Eid, T.	Introduzindo o viés no gerador de solução candidata para selecionar as MUs em SA (Métodos 2 e 3) melhorou o desempenho comparado com o método convencional (Método 1).	Planejamento Florestal/Tático/Espacial
2014	Applying simulated annealing using different methods for the neighborhood search in forest planning problems.	SA	Borges, P.; Eid, T.; Bergseng, E.	Introduzindo um viés na busca de vizinhança para selecionar unidades de manejo em SA está em geral melhorando as soluções.	Planejamento Florestal/Tático/Espacial
2014	Efficiency in forest management: A multiobjective harvest scheduling model.	SS/E	Hernandez, M.; Gómez, T.; Molina, J., León, M.A.; Caballero, R.	Consideramos que a aplicação de modelos de decisão multiobjetivos para a silvicultura pode ser de grande utilidade.	Planejamento Florestal/ M.O /Espacial
2015	Spatial forest resource planning using a cultural algorithm with problem-specific information.	AC/E	Liu, W.Y.; Lin, C.C.	O princípio é adicionar um espaço de crença aos algoritmos evolucionários, no qual um líder e uma matriz normativa ou influências situacionais e normativas que atuam sobre toda a população, para encontrar melhores soluções.	Planejamento Florestal/Tático/Espacial

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2015	Search reversion within s-metaheuristics: impacts illustrated with a forest planning problem.	BT, TA, RD	Bettinger, P.; Demirci, M.; Boston, K.	Os resultados sugeriram que a reversão pode ser um aspecto necessário na BT e TA	Planejamento Florestal/Tático/Espacial
2015	Analysis of the performance of different implementations of a heuristic method to optimize forest harvest scheduling.	SA	Bachmatiuk, J.; Garcia-Gonzalo, J.; Borges, J.G.	Com esses resultados, concluímos que, no algoritmo SA, o número de prescrições disponíveis para cada unidade de manejo tem um impacto na configuração de qual movimento opt-move para usar.	Planejamento Florestal/Tático/Espacial
2015	A comparison of a neighborhood search technique for forest spatial harvest scheduling problems: A case study of the simulated annealing algorithm.	SA	Dong, L.; Bettinger, P.; Liu, Z.; Qin, H.A.	Os resultados sugerem que a utilização de um 2-opt move em vez de um 1-opt na procura de vizinhança melhorou claramente os valores da função objetivo, mas também diminuiu significativamente os desvios padrão do conjunto de soluções	Planejamento Florestal/Tático/Espacial
2015	An evaluation of the use of simulated annealing to optimize thinning rates for single even-aged stands.	SA	Moriguchi, K.; Ueki, T.; Saito, M.	Indicou que a SA geralmente proporcionou melhores soluções	Planejamento/ Otimização Desbastes
2015	Multi-objective spatial forest planning using self-organization.	SO/E	Fotakis, D.G.	Três soluções diferentes da frente de Pareto são apresentadas: a duas soluções de ponto final e mais uma solução intermediária indicativa.	Planejamento Florestal/ M.O /Espacial
2016	A multilevel ACO approach for solving forest transportation planning problems with environmental constraints.	ACO	Lin, P.; Contreras, M.A.; Dai, R.; Zhang, J.	Estes resultados indicam o grande potencial da abordagem geral de multi-level ACO, servem como um quadro generalizado para resolver problemas de transporte no mundo real.	Planejamento Florestal/Transporte/Espacial
2016	Promoting harvesting stands connectivity and its economic implications in Brazilian forest plantations applying integer linear programming and simulated annealing.	SA	Augustynczyk, A.L.D.; Arce, J.E.; Yousefpour, R.; Da Silva, A.C.L.	A abordagem de SA é adequada para médio a grande problemas.	Planejamento Florestal/Estratégico/Espacial
2016	Evaluating the neighborhood, hybrid and reversion search techniques of a simulated annealing algorithm in solving forest spatial harvest scheduling problems.	SA	Dong, L.; Bettinger, P.; Liu, Z.; Qin, H.; Zhao, Y.	Portanto, nós podemos concluir que os algoritmos heurísticos, incluindo o SA, precisam de alguns refinamentos necessários para produzir soluções de melhor qualidade na prática	Planejamento Florestal/Tático/Espacial
2017	Modelling the spatial forest-thinning planning problem considering carbon sequestration and emissions.	SA	Liu, W.Y.; Lin, C.C.; Su, K.H.	O desempenho da ISA foi consideravelmente superior ao do legado SA.	Planejamento/ Otimização Desbastes

Ano	Título	Meta-heurísticas	Autores	Conclusões	Assunto
2017	Identification of effective implementations of simulated annealing for optimizing thinning schedules for single forest stands.	SA	Moriguchi, K.; Ueki, T.; Saito, M.	Para estabelecer um método de otimização confiável para sequenciamento de desbastes de stands individuais, com o objetivo de fornecer aos engenheiros um método confiável para suas tarefas diárias de consultoria.	Planejamento/ Otimização Desbastes

Legenda, AC = Autômatos Celulares; AC/E = Algoritmo Cultural; ACO = Colônia de formigas; AG/E= Algoritmo Genético; BT = Busca Tabu; EPO = Enxame de partículas; GD = Great deluge; GRASP = Greedy Randomized Adaptative Search Procedure; HC=Hill Climbing; HO = HERO; Hy= Híbrida; IC=Interchange; ISA = Indirect Search Algorithm; MC = Monte Carlo; RA= Random ascent; RD= Rain Drop; RS = Random Search; RR= RazãoR; SA = Simulated Annealing ; SS/E = Scatter Search; SO/E= Self-organization; TA= Threshold accepting;

4 – Considerações finais

A revisão bibliográfica apresentada mostra algumas das principais aplicações de meta-heurísticas em problemas de planejamento florestal hierárquico, é possível observar que um mesmo problema pode ser resolvido empregando diferentes meta-heurísticas, em alguns casos utilizando mais de uma meta-heurística ou de abordagens híbridas, combinando qualidades de intensificação e diversificação do espaço de soluções, cabendo ao pesquisador descobrir a melhor opção a ser utilizada para resolver seu problema. Esta escolha muitas vezes é definida em função do esforço computacional e da qualidade das soluções, fazendo dos métodos exatos indispensáveis no desenvolvimento e implementação das meta-heurísticas em problemas menores.

Algumas meta-heurísticas já foram extensivamente aplicadas ao problema de planejamento florestal hierárquico, como Algoritmo Genético, Simulated Annealing e Busca Tabu demonstrando sucesso em resolver estes problemas. Outras ainda precisam ter sua aplicabilidade e eficiência melhor avaliadas.

5 - Referências Bibliográficas.

ARMENTANO, V.A.; BRANCHINI, R.M. Uma Introdução à Busca Tabu. **In: Meta-heurísticas em Pesquisa Operacional** (HS Lopes & LCA Rodrigues & MTA Steiner, eds.), p.33-52.2013.

AUGUSTYNCZIK, A.L.D.; ARCE, J.E.; YOUSEFPOUR, R.; DA SILVA, A.C.L. Promoting harvesting stands connectivity and its economic implications in Brazilian forest plantations applying integer linear programming and simulated annealing. **Forest Policy and Economics**, v.73, n.1, p.120-129. 2016.

BACHMATIUK, J.; GARCIA-GONZALO, J.; BORGES, J.G. Analysis of the performance of different implementations of a heuristic method to optimize forest harvest scheduling. **Silva Fennica**, v.49, n.4, p.1-18. 2015.

BARÃO, F.R.; KRIPKA, M; KRIPKA, R.M.L. Modelagem Matemática para Coleta Seletiva no Município de Passo Fundo-RS,". **Meta-heurísticas em Pesquisa Operacional** "(HS Lopes and LCA Rodrigues and MTA Steiner, eds.), p.237-252.2013.

BARROS JUNIOR, A. A.; ARROYO, J. E. C.; SANTOS, H. N. GRASP com path relinking para um problema de planejamento florestal, **Anais do XLI SBPO - Simpósio Brasileiro de Pesquisa Operacional**. p. 1953-1964. 2009.

BASKENT, E.Z.; JORDAN, G.A. Forest landscape management modeling using simulated annealing. **Forest Ecology and Management**, v.165, n.(1), p.29-45. 2002.

BETTINGER, P.; SESSIONS, J.; CHUNG, W.; GRAETZ, D.; BOSTON, K. Eight Heuristic Planning Techniques Applied to Three Increasingly Difficult Wildlife Planning Problems. **Silva Fennica**, v.36, n.2, p.561-584.2002.

BETTINGER, P.; BOSTON, K.; KIM, Y.H.; ZHU, J. Landscape-level optimization using tabu search and stand density-related forest management prescriptions. **European Journal of Operational Research**, v.176, n.2, p.1265-1282. 2007.

BETTINGER, P.; BOSTON, K.; SESSIONS, J. Intensifying a heuristic forest harvest scheduling search procedure with 2-opt decision choices. **Canadian Journal of Forest Research**, v.29, n.11, p.1784-1792. 1999.

BETTINGER, P.; DEMIRCI, M.; BOSTON, K. Search reversion within s-metaheuristics: impacts illustrated with a forest planning problem. **Silva Fennica**, v.49, n.2, p.1-20, 2015.

BETTINGER, P.; JOHNSON, D.L.; JOHNSON, K.N. Spatial forest plan development with ecological and economic goals. **Ecological Modelling**, v.169, n.2, p.215-236. 2003.

BETTINGER, P.; SESSIONS, J.; BOSTON, K. Using tabu search to schedule timber harvests subject to spatial wildlife goals for big game. **Ecological Modelling**, v.94, n.2-3, p.111-123. 1997.

BETTINGER, P.; ZHU, J. A new heuristic method for solving spatially constrained forest planning problems based on mitigation of infeasibilities radiating outward from a forced choice. **Silva Fennica**, v.40, n.2, p.315-332. 2006.

BINOTI, D.H.B.; BINOTI, M.L.M.D.S.; LEITE, H.G.; GLERIANI, J.M.; OLIVEIRA, M.L.R.D.; CAMPOS, J.C.C.; SOUZA, A.L.D.; RIBEIRO, C.A.Á.S. Regulação de florestas equiâneas com restrição de classes de idade por compartimento. **CERNE**, v.20, n.4, p. 567-573, 2014.

BINOTI, D.H.B.; BINOTI, M.L.M.D.S.; LEITE, H.G.; GLERIANI, J.M.; RIBEIRO, C.A.Á.S., Inclusion and effect of spatial characteristics on models of forest regulation. **CERNE**, v.20, n.1, p.157-164. 2014.

BINOTI, D.H.B.; DA SILVA BINOTI, M.L.M.; LEITE, H.G.; GLERIANI, J.M.; CAMPOS, J.C.C. Regulation of even-aged forest with adjacency constraints. **Forest policy and economics**, v.20, n.1, p.49-57. 2012.

BONABEAU, E.; DORIGO, M.; THERAULAZ, G. **Swarm intelligence: from natural to artificial system** (No. 1). Oxford university press. 1999.

BORGES, P.; BERGSENG, E.; EID, T. Adjacency constraints in forestry-A simulated annealing approach comparing different candidate solution generators. **Mathematical and Computational Forestry & Natural Resource Sciences**, v.6, n.1, p.11-25. 2014.

BORGES, P.; EID, T.; BERGSENG, E. Applying simulated annealing using different methods for the neighborhood search in forest planning problems. **European Journal of Operational Research**, v.233, n.3, p.700-710. 2014.

BOSTON, K.; BETTINGER, P. An analysis of Monte Carlo integer programming, simulated annealing, and tabu search heuristics for solving spatial harvest scheduling problems. **Forest science**, v.45, n.2, p.292-301. 1999.

BOSTON, K.; BETTINGER, P. Development of spatially feasible forest plans: a comparison of two modeling approaches. **Silva Fennica**, v.35, n.4, p.425-435. 2001.

BOSTON, K.; BETTINGER, P. Combining tabu search and genetic algorithm heuristic techniques to solve spatial harvest scheduling problems. **Forest Science**, v.48, n.1, p.35-46, 2002.

BOSTON, K.; BETTINGER, P. An economic and landscape evaluation of the green-up rules for California, Oregon, and Washington (USA). **Forest Policy and Economics**, v.8, n.3, p.251-266. 2006.

BOSTON, K.; BETTINGER, P. The economic impact of green-up constraints in the southeastern United States. **Forest Ecology and Management**, v.145, n.3, p.191-202. 2001.

BRUMELLE, S.; GRANOT, D.; HALME, M.; VERTINSKY, I. A tabu search algorithm for finding good forest harvest schedules satisfying green-up constraints. **European Journal of Operational Research**, v.106, n.2-3, p.408-424.1998.

BURLA, E. R. **Avaliação técnica e econômica do “harvester” na colheita do eucalipto**. 2008. 62f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, MG, 2008.

CARO, F.; CONSTANTINO, M.; MARTINS, I.; WEINTRAUB, A. A 2-opt tabu search procedure for the multiperiod forest harvesting problem with adjacency, greenup, old growth, and even flow constraints. **Forest Science**, v.49, n.5, p.738-751.2003.

CARDOSO MACHADO, C.; SILVA LOPES, E.D., Análise da influência do comprimento de toras de eucalipto na produtividade e custo da colheita e transporte florestal. **CERNE**, v.6, n.2. p.124-129, 2000.

CERNY, V. A thermo dynamical approach to the traveling salesman problem: An efficient simulation algorithm. **Journal of Optimization Theory and Applications**, n.45, p.41–51, 1985.

COLEY, D. A. **An Introduction to genetic algorithms for scientists and engineers**. World Scientific, 1999. 244p.

CROWE, K.; NELSON, J. An indirect search algorithm for harvest-scheduling under adjacency constraints. **Forest Science**, v.49, n.1, p.1-11. 2003.

CROWE, K.; NELSON, J.; An evaluation of the simulated annealing algorithm for solving the area-restricted harvest-scheduling model against optimal benchmarks. *Canadian Journal of Forest Research*, v.35, n.10, pp.2500-2509. 2005.

DAHLIN, B.; SALLNÄS, O. Harvest scheduling under adjacency constraints—a case study from the Swedish sub-alpine region. **Scandinavian Journal of Forest Research**, v.8, n.(1-4), p.281-290. 1993.

DONG, L.; BETTINGER, P.; LIU, Z.; QIN, H.; ZHAO, Y. Evaluating the neighborhood, hybrid and reversion search techniques of a simulated annealing algorithm in solving forest spatial harvest scheduling problems. **Silva Fennica**, v.50, n.4. p.1-20. 2016.

DONG, L.; BETTINGER, P.; LIU, Z.; QIN, H. A comparison of a neighborhood search technique for forest spatial harvest scheduling problems: A case study of the simulated annealing algorithm. **Forest Ecology and Management**, v.356, p.124-135. 2015.

DORIGO, M.; BLUM, C. Ant colony optimization theory: A survey. **Theoretical computer science**, v.344, n.2-3, p.243-278. 2005.

DORIGO, M.; DI CARO, G.; GAMBARDELLA, L.M. Ant algorithms for discrete optimization. **Artificial life**, v.5, n.2, p.137-172. 1999.

DUCHEYNE, E.; DE WULF, R.R.; DE BAETS, B. Single versus multiple objective genetic algorithms for solving the even-flow forest management problem. **Forest Ecology and Management**, v.201, n.15, p. 259–273. 2004.

EBERHART, R.; KENNEDY, J., A new optimizer using particle swarm theory. In **Micro Machine and Human Science**, October, 1995. MHS'95. Proceedings of the Sixth International Symposium on (p. 39-43). IEEE. 1995.

EGLESE, R.W. Simulated annealing a tool for operational research. **European journal of operational research**, v.46, n.3, p.271-281. 1990.

FEO, T.A.; RESENDE, M.G. Greedy randomized adaptive search procedures. **Journal of global optimization** v.6, n.2, p.109-133. 1995.

FOTAKIS, D.G. Multi-objective spatial forest planning using self-organization. **Ecological Informatics**, v.29, n.1, p.1-5. 2015.

FOTAKIS, D.G.; SIDIROPOULOS, E.; MYRONIDIS, D.; IOANNOU, K. Spatial genetic algorithm for multi-objective forest planning. **Forest Policy and Economics**, v.21, p.12-19. 2012.

GARCIA-GONZALO, J.; BORGES, J.G.; HILEBRAND, W.; PALMA, J. Comparison of effectiveness of different implementations of a heuristic forest harvest scheduling search procedure with different number of decision choices simultaneously changed per move. **Lecture Notes in Management Science**, v.4, p.179-183. 2012.

GENDREAU, M.; J POTVIN, J.Y. An introduction to tabu search. **In: Handbook of metaheuristics**. Fred Glover e Gary A. Kochenberger (eds.) p. 41-59. Springer US. 2010.

GENDREAU, M.; J POTVIN, J.Y. Tabu search. **In Search methodologies** (p. 243-263). Springer US. 2014.

GENDREAU, M.; J POTVIN, J.Y. **Handbook of metaheuristics**. Vol. 2. New York: Springer, 648p. 2010.

GLOVER, F. Tabu search: A tutorial. **Interfaces** v.20, n.4, p.74-94. 1990.

GLOVER, F.; LAGUNA, M. **Tabu Search** Springer Science New York. 1997.

GLOVER, F.; TAILLARD, E., A user's guide to tabu search. **Annals of operations research**, v.41, n.1, p.1-28. 1993.

GÓMEZ, T.; HERNÁNDEZ, M.; MOLINA, J.; LEÓN, M.A.; ALDANA, E.; CABALLERO, R. A multiobjective model for forest planning with adjacency constraints. **Annals of Operations Research**, v.190, n.1, p.75-92. 2011.

GOMIDE, L. R.; ARCE, J. E.; DA SILVA, A. C. L. Uso do algoritmo genético no planejamento florestal considerando seus operadores de seleção. **CERNE**, v.15, n.4, p.460-467. 2009.

GOMIDE, L.R.; ARCE, J.E.; DA SILVA, A.C.L. Comparação entre a meta-heurística simulated annealing e a programação linear inteira no agendamento da colheita florestal com restrições de adjacência. **Ciência Florestal**, v.23, n.2, p.449-460. 2013.

GONZÁLEZ-OLABARRIA, J.R.; PUKKALA, T. Integrating fire risk considerations in landscape-level forest planning. **Forest Ecology and Management**, v.261, n.2, p.278-287. 2011.

GOLBERG, D.E., **Genetic algorithms in search, optimization, and machine learning**. Addison Wesley. Reading. 1989.

HANSEN, P.; MLADENOVIC, N.; BRIMBERG, J.; PÉREZ, J.A.M. Variable neighborhood search **In: Handbook of metaheuristics**. (ed) Michel Gendreau and Jean-Yves Potvin pp. 61-59. Springer US. 2010.

HEINONEN, T.; PUKKALA, T. A comparison of one-and two-compartment neighbourhoods in heuristic search with spatial forest management goals. **Silva Fennica**, v.38, n.3, p.319-332. 2004.

HEINONEN, T.; PUKKALA, T. The use of cellular automaton approach in forest planning. **Canadian Journal of Forest Research**, v.37, n.11, p.2188-2200. 2007.

HEINONEN, T.; PUKKALA, T.; IKONEN, V.P.; PELTOLA, H.; GREGOW, H.; VENÄLÄINEN, A. Consideration of strong winds, their directional distribution and snow loading in wind risk assessment related to landscape level forest planning. **Forest ecology and management**, v.261, n.3, p.710-719. 2011.

HEINONEN, T.; PUKKALA, T.; IKONEN, V.P.; PELTOLA, H.; VENÄLÄINEN, A.; DUPONT, S. Integrating the risk of wind damage into forest planning. **Forest Ecology and Management**, v.258, n.7, p.1567-1577. 2009.

HENDERSON, D.; JACOBSON, S.H.; JOHNSON, A.W. The theory and practice of simulated annealing. In: Fred Glover e Gary A. Kochenberger (eds.), **Handbook of Metaheuristics** p. 287-319. 2003.

HERNANDEZ, M.; GÓMEZ, T.; MOLINA, J., LEÓN, M.A.; CABALLERO, R. Efficiency in forest management: A multiobjective ha

JAZIRI, W. **Local search techniques: focus on tabu search**. Published by In-The in September. 278p. 2008.

JOHNSON, K.N.; SCHEURMAN, H.L. Techniques for prescribing optimal timber harvest and investment under different objectives: discussion and synthesis. **Forest Science Monography** v.23, n.1, p.1–31, 1977.

KAVEH, A.; TALATAHARI, S. Particle swarm optimizer, ant colony strategy and harmony search scheme hybridized for optimization of truss structures. **Computers & Structures**, v.87, n.5, p.267-283, 2009.

KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by simulated annealing. **Science**, v.4598, n.220, p.671–680, 1983.

LEGÜES, A.D.; FERLAND, J.A.; RIBEIRO, C.C.; VERA, J.R.; WEINTRAUB, A. A tabu search approach for solving a difficult forest harvesting machine location problem. **European Journal of Operational Research**, v.179, n.3, p.788-805. 2007.

LIANG, Y.C.; CHEN, H.L.A.; TIEN, C.Y. Variable neighborhood search for multi-objective parallel machine scheduling problems. **In Proceedings of the 8th International Conference on Information and Management Sciences** p. 519-522. 2009.

LIEN, L.C.; CHENG, M.Y. A hybrid swarm intelligence based particle-bee algorithm for construction site layout optimization. **Expert Systems with Applications**, v.39, n.10, p.9642-9650. 2012.

LIN, P.; CONTRERAS, M.A.; DAI, R.; ZHANG, J. A multilevel ACO approach for solving forest transportation planning problems with environmental constraints. **Swarm and Evolutionary Computation**, v.28,n.1, p.78-87.2016.

LIU, G.; HAN, S.; ZHAO, X.; NELSON, J. D.; WANG, H.; WANG, W. Optimisation algorithms for spatially constrained forest planning. **Ecological Modelling**, v.194, n.4, p.421-428. 2006.

LI, R., BETTINGER, P. ; BOSTON, K., Informed development of metaheuristics for spatial forest planning problems. **The Open Operational Research Journal**, v.4, n.1, 2010.

LIU, G.; NELSON, J.D.; WARDMAN, C.W. A target-oriented approach to forest ecosystem design—changing the rules of forest planning. **Ecological Modelling**, v.127, n.2, p.269-281. 2000.

LIU, W.Y.; LIN, C.C. Spatial forest resource planning using a cultural algorithm with problem-specific information. **Environmental Modelling & Software**, v.71, n.1, p.126-137. 2015.

LIU, W.Y.; LIN, C.C.; SU, K.H. Modelling the spatial forest-thinning planning problem considering carbon sequestration and emissions. **Forest Policy and Economics**, v.78, p.51-66. 2017.

LOCKWOOD, C.; MOORE, T. Harvest scheduling with spatial constraints: a simulated annealing approach. **Canadian journal of forest research**, v.23, n.3, p.468-478. 1993.

LU, F.; ERIKSSON, L.O. Formation of harvest units with genetic algorithms. **Forest Ecology and Management**, v.130, n.1, p.57-67. 2000.

MATHEY, A.H.; KRUMHOLTZ E.; DRAGICEVIC S.; VERTINSKY, I. An object-oriented cellular automata model for forest planning problems. **Ecological Modelling**. v.3, n.212, p.359-371. 2008.

MATHEY, A.H.; KRUMHOLTZ, E.; TAIT, D.; VERTINSKY, I; INNES, J. Forest planning using co-evolutionary cellular automata. **Forest ecology and management**, v.239, n.1, p.45-56.2007.

- MEIGNAN, D.; FRAYRET, J.M.; PESANT, G.; BLOUIN, M. A heuristic approach to automated forest road location. **Canadian journal of forest research**, v.42, n.12, p.2130-2141. 2012.
- MELIDO, R. C. N. **Avaliação técnica e econômica de dois projetos florestais com eucalipto para fins energéticos**. Dissertação de Mestrado em Engenharia Florestal, Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF, 113 p. (2012).
- MERKLE, D.; MIDDENDORF, M. Swarm intelligence. **In Search methodologies** (P. 213-242). Springer US. 2014.
- METROPOLIS, N.; ROSENBLUTH, A.W.; ROSENBLUTH, M.N.; TELLER, A.H.; TELLER, E. Equation of state calculations by fast computing machines. **The journal of chemical physics**. v.21, n.6, p.1087-1092. 1953.
- MLADENOVIC, N.; HANSEN, P. Variable neighborhood search. **Computers & operations research**. v.24, n.11, p.1097-1100. 1997.
- MOREIRA, J.M.M.Á.P.; RODRIGUEZ, L.C.E., A incorporação de corredores de conectividade no manejo de florestas industriais utilizando a heurística da RazãoR. **Revista de Economia e Sociologia Rural**, v.48, n.2, p.255-282. 2010.
- MORIGUCHI, K.; UEKI, T.; SAITO, M. Identification of effective implementations of simulated annealing for optimizing thinning schedules for single forest stands. **European Journal of Operational Research**, v.3, n.262, p.1094-1108. 2017.
- MORIGUCHI, K.; UEKI, T.; SAITO, M. An evaluation of the use of simulated annealing to optimize thinning rates for single even-aged stands. **International Journal of Forestry Research**, v.2015, p.1-15. 2015.
- MURRAY A.T. Spatial restrictions in harvest scheduling. **Forest Science**, v.45, n.1, p.45-52. 1999.
- MURRAY, A. T.; CHURCH, R. L. Heuristic solution approaches to operational forest planning problems. **OR Spectrum**, v.17, n.2, p.193-203. 1995.
- NASCIMENTO, F. A. F. D.; DIAS, A. N.; FIGUEIREDO FILHO, A.; ARCE, J. E.; MIRANDA, G. D. M. Uso da Meta-Heurística otimização por exame de partículas no planejamento florestal. **Scientia Florestalis**, v. 40, n. 96, p. 557-565. 2012.
- NELSON, J.; BRODIE, J.D. Comparison of a random search algorithm and mixed integer programming for solving area-based forest plans. **Canadian journal of forest research**, v.20, n.7, p.934-942. 1990.
- ÖHMAN, K. Creating continuous areas of old forest in long-term forest planning. **Canadian Journal of Forest Research**, v.30, n.11, p.1817-1823. 2000.

ÖHMAN, K.; ERIKSSON, L.O. The core area concept in forming contiguous areas for long-term forest planning. **Canadian Journal of Forest Research**, v.28, n.7, p.1032-1039. 1998.

ÖHMAN, K.; ERIKSSON, L.O. Allowing for spatial consideration in long-term forest planning by linking linear programming with simulated annealing. **Forest Ecology and Management**, v.161, n.1, p.221-230. 2002.

ÖHMAN, K.; LÄMÅS, T. Reducing forest fragmentation in long-term forest planning by using the shape index. **Forest Ecology and Management**, v.212, n.1, p.346-357. 2005.

ÖHMAN, K.; LÄMÅS, T. Clustering of harvest activities in multi-objective long-term forest planning. **Forest ecology and management**, v.176, n.1, p.161-171. 2003.

OLIVEIRA, M. L. R.; LEITE, H.G.; NOGUEIRA, G.S.; CAMPOS, J.C.C. Modelagem e prognose em povoamentos não desbastados de clones de eucalipto. **Revista Árvore**, v.33, n.5, p.841-852, 2009.

PHAM, D.; KARABOGA, D., **Intelligent optimisation techniques: genetic algorithms, tabu search, simulated annealing and neural network**. Springer Science & Business Media. 2012.

PUKKALA, T.; HEINONEN, T. Optimizing heuristic search in forest planning. **Nonlinear analysis: real world applications**, v.7, n.5, p.1284-1297. 2006.

PUKKALA, T.; KURTTILA, M. Examining the performance of six heuristic optimisation techniques in different forest planning problems. **Silva Fennica**, v.39, n.1, p.67-80. 2005.

RESENDE, M. G. C.; RIBEIRO, C. C. Greedy randomized adaptive search procedures. **In: Handbook of Metaheuristics**, Fred Glover e Gary A. Kochenberger (eds.), p.219-250. Kluwer Academic Publishers, Norwell, MA, 2002.

RICHARDS, E.W.; GUNN, E.A. Tabu search design for difficult forest management optimization problems. **Canadian Journal of Forest Research**, v.33, n.6, p.1126-1133. 2003.

RICHARDS, W.; GUNN, A. A model and tabu search method to optimize stand harvest and road construction schedules. **Forest Science**, v.46, n.2, p.188-203. 2000.

RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. N.; SOUZA, A. L. Solução de problemas de planejamento florestal com restrições de inteireza utilizando busca tabu. **Revista Árvore**, v.27, n.5, p.701- 713. 2003.

RODRIGUES, F.L.; LEITE, H.G.; SANTOS, H.D.N., SOUZA, A.L.D.; SILVA, G.F.D. Metaheurística algoritmo genetic para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, v.22, n.2, p.233-245. 2004.

RODRIGUES, F.L.; LEITE, H.G.; SANTOS, H.D.N.; SOUZA, A.L.D.; RIBEIRO, C.A.Á.S. Metaheurística Simulated Annealing para solução de problemas de

planejamento florestal com restrições de integridade. **Revista Árvore**, v.28, n.2, p.247-256, 2004.

SAKAWA, M. **Genetic algorithms and fuzzy multiobjective optimization** (Vol. 14). Springer Science & Business Media. p.288, 2012.

SEAN, LUKE. **Essentials of Metaheuristics**, 2º edition, disponível em: <http://cs.gmu.edu/~sean/book/metaheuristics/.2013>.

SILVA, G. F.; PIASSI, L. C.; MÔRA, R.; MARTINS, L. T.; TEIXEIRA, A. F.; BARROS JUNIOR, A. A. Meta-heurística algoritmo genético na solução de modelos de planejamento florestal. **Revista Brasileira de Ciências Agrárias**. v.4, n. 2, p.160-166. 2009.

SIVANANDAM, S.N.; DEEPA, S.N. **Introduction to genetic algorithms**. Springer Science & Business Media. 2007.

STRIMBU, B.M.; PAUN, M. Sensitivity of forest plan value to parameters of simulated annealing. **Canadian journal of forest research**, v.43, n.1, p.28-38. 2012.

TALBI, EL-GHAZALI. **Metaheuristics: from design to implementation**. John Wiley & Sons, 593p. 2009.

THOMPSON, M.P.; HAMANN, J.D.; SESSIONS, J. Selection and penalty strategies for genetic algorithms designed to solve spatial forest planning problems. **International Journal of Forestry Research**, v.2009, p.1-14, 2009.

TONETTO ALVES, R.; FIEDLER, N.C.; NEIRE DA SILVA, E.; DA SILVA LOPES, E.; DE ASSIS DO CARMO, F.C., Análise técnica e de custos do transporte de madeira com diferentes composições veiculares. **Revista Árvore**, v.37, n.5. P.897-904, 2013.

YANG, X.S. **Engineering optimization: an introduction with metaheuristic applications**. John Wiley & Sons; 347p. 2010.

YIN, P.Y.; WANG, T.Y. A GRASP-VNS algorithm for optimal wind-turbine placement in wind farms. **Renewable energy**. v.48, n.C, p.489-498. 2012.

ZENG, H.; PUKKALA, T.; PELTOLA, H. The use of heuristic optimization in risk management of wind damage in forest planning. **Forest Ecology and Management**, v.41, n.1, p.189-199. 2007.

ZENG, H.; PUKKALA, T.; PELTOLA, H.; KELLOMAKI, S. Application of ant colony optimization for the risk management of wind damage in forest planning. **Silva Fennica**, v.41, n.2, p.315-332, 2007.

ZHU, J.; BETTINGER, P. Estimating the effects of adjacency and green-up constraints on landowners of different sizes and spatial arrangements located in the southeastern US. **Forest policy and economics**, v.10, n.5, p.295-302, 2008.

CAPÍTULO 2 - UM SISTEMA DE SUPORTE A DECISÃO NO PLANEJAMENTO FLORESTAL ESTRATÉGICO.

1 - Introdução

O planejamento florestal estratégico está em muitos aspectos, ligado a essência da silvicultura tradicional que começou no século XIX na Europa, com ênfase na regulação do fluxo de madeira. Desde então, evoluiu para o seu foco atual em gestão de florestas sustentáveis. Planos de manejo florestal projetados para maximizar fluxos constantes de volume de madeira deram lugar ao manejo florestal sustentável, compatível com a visão da Comissão Brundtland sobre a sustentabilidade e desenvolvimento (Comissão Mundial de Meio Ambiente e desenvolvimento, 1987). Os engenheiros florestais são confrontados com o desafio não trivial de preservar ecossistemas naturais e satisfazer demandas crescentes de plantas industriais, a partir de uma base de terra decrescente. Este desafio é muitas vezes, não para identificar um solução ideal, mas sim encontrar uma solução viável e exequível (MARTELL et al., 1998).

Para gerar o plano de manejo florestal é necessário simular diferentes cenários, considerando restrições sociais, ambientais e econômicas que podem ocorrer na floresta no qual o empreendimento está inserido, como: aumento de impostos, variação nas empresas prestadoras de serviços, custos de colheita ou silvicultura, venda de terras da empresa ou aquisição de novas áreas, aumento ou diminuição das demandas mínimas exigidas, dentre outros. Sendo assim a solução dos problemas de regulação florestal demandam sistemas computacionais (RODRIGUES, 2001).

A resolução de problemas de planejamento florestal, com algoritmos exatos, com restrições de adjacência, podem levar muitas horas, se não dias (MCDILL; BRAZE, 2000). Sendo assim muitas pesquisas propondo algoritmos aproximativos para solucionar o problema foram desenvolvidas (BORGES et al., 2014; DONG et al., 2015; GOMIDE et al., 2013). As meta-heurísticas mais utilizadas para resolver estes problemas são reconhecimento simulado (LOCKWOOD AND MOORE, 1993; ÖHMAN AND ERIKSSON, 1998; BACHMATIUK et al., 2015; DONG et al., 2018), algoritmo genético (LU AND ERIKSSON, 2000; THOMPSON et al., 2009; BINOTI et al., 2012, BINOTI et al., 2014) e busca tabu (BETTINGER et al., 1997; CARO et al., 2003; LEGÜES et al., 2007), porém existem outras meta-heurísticas com enorme potencial para serem aplicadas

ao problema com a Greedy randomized adaptative search procedure, Variable Neighborhood Search, Guided Local Search, além de abordagens híbridas.

2- Objetivos

O objetivo desse estudo foi de desenvolver e implementar e validar uma interface para aplicação das meta-heurísticas Simulated annealing, Algoritmo Genético, GRASP e VNS e uma abordagem híbrida, para resolução de problemas de planejamento florestal estratégico com restrições de demanda, regulação e adjacência.

3- Material e Métodos

A linguagem de programação utilizada para implementação das meta-heurísticas e da interface do usuário foi a C#. Para o desenvolvimento da interface, foi utilizada a tecnologia desenvolvida pela Microsoft, Windows Presentation Foundation (WPF), o Visual Studio 2017 Community Edition, como IDE de apoio para desenvolvimento do trabalho, as bibliotecas OxyPlot, Mahapps.metro. O arquivo de entrada para o sistema é uma planilha MS Excel xlsx, ou no formato json. Os testes foram realizados em ambiente windows. As MH desenvolvidas e implementadas assim como o instalador do programa estão disponíveis no endereço web <https://github.com/Matheus-Aguilar/mheuristics-interface>.

A interface foi desenvolvida para resolver problemas de planejamento florestal estratégico, utilizando a programação inteira mista, seguindo os critérios de formulação do modelo I (Johnson e Scheurman, 1977).

3.1 - Definindo o problema

O modelo de otimização empregado para solucionar o problema de planejamento florestal espacial, foi o modelo I, proposto originalmente por Kidd et al. (1966), e assim denominado por Johnson e Scheurman (1977). Com o objetivo de maximizar o Valor Presente Líquido (VPL) da floresta, a função objetivo foi estabelecida da seguinte forma:

$$\text{Max}Z = \sum_{i=1}^m \sum_{j=1}^n C_{ij} X_{ij} \quad (1)$$

S.t.

$$\sum_{i=1}^m \sum_{j=1}^n X_{ij} = 1 \forall i = (1 \dots m) \quad (2)$$

$$\sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij} \geq D \min \forall k = (0 \dots h-1) \quad (3)$$

$$\sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij} \leq D \max \forall k = (0 \dots h-1) \quad (4)$$

$$V_{H(k+1)} \geq (1 - \alpha) V_{H(k)} \forall k = (0 \dots h-1) \quad (5)$$

$$V_{H(k+1)} \leq (1 + \beta) V_{H(k)} \forall k = (0 \dots h-1) \quad (6)$$

$$\sum_{i=1}^m \sum_{j=1}^n A_{ijk} X_{ij} \geq \frac{A_k}{r} (1 - \lambda) \forall k = (1 \dots r) \quad (7)$$

$$\sum_{i=1}^m \sum_{j=1}^n A_{ijk} X_{ij} \leq \frac{A_k}{r} (1 + \lambda) \forall k = (1 \dots r) \quad (8)$$

$$n_i X_{ij} + \sum_{i \in N_i} X_{ij} \leq n_i \forall i, k. \quad (9)$$

$$X_{ij} \in \{0, 1\} \quad (10)$$

$$\text{sendo : } V_{HK} = \sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij}$$

em que:

Z = valor presente líquido global (R\$); X_{ij} = variáveis de decisão, representando o j -ésima prescrição de manejo adotada na i -ésima UM; C_{ij} = valor presente líquido de cada unidade de manejo i , gerenciada com a prescrição de manejo j ; M = número total de unidades de manejo (UM); N = total de prescrições de manejo para o i -ésima UM; V_{ijk} = volume (m^3) produzido no período k , através de i -ésima UM adotando a j -ésima prescrição de manejo; $Dmin_k$ e $Dmax_k$ são as demandas mínimas e o máximas volumétricas (m^3), respectivamente, em cada período do horizonte de planejamento. n_i refere-se ao número de unidades de manejo adjacentes que apresentam cortes no período k .

De acordo com a função objetivo do modelo de programação inteira mista, (1), o objetivo é maximizar o valor presente global, sujeito as restrições de singularidade,

(2,10), produções mínimas (3) e máximas (4) em cada período do horizonte de planejamento, controle sobre o fluxo de produção durante o horizonte de planejamento (5,6), e regulação da produção (7,8), que permite uma variação α para flexibilizar o atendimento dessa restrição. A restrição (9), assegura que nenhuma área adjacente será cortada no mesmo período k.

A restrição de adjacência por unidade (URM), proposta por Murray (1999), foi assumida para o problema. A avaliação da dispersão das intervenções nas unidades de manejo foi realizada utilizando a média ponderada do inverso da menor distância entre unidades de manejo cortadas no mesmo período, pelas áreas das unidades de manejo que sofrem intervenção. Quando menor o valor apresentado pelo IAC, melhor ambientalmente será o plano de manejo (BINOTI, 2012 ; BASKET E JORDAN, 1995).

O índice utilizado foi :

$$IAC = \left(\frac{\sum_{k=0}^{h-1} \sum_{i=1}^m A_i^2 \left(\frac{1}{d_i}\right)^2}{\sum_{i=1}^m A_i} \right)$$

em que IAC = índice de área sem cobertura florestal, A_i = área da unidade de manejo i com intervenção, em hectares, d_i = distância ate a unidade de manejo mais próxima com intervenção, em quilômetros, k= ano do horizonte de planejamento, h=horizonte de planejamento, m = número total de unidades de manejo.

3.2 - Representação da solução

A representação da solução é feita utilizando um vetor de tamanho n, onde n corresponde ao numero de unidades de manejo do problema. Para cada posição do vetor é assinalado um numero de 1 a j que corresponde ao número de prescrições. Um exemplo: seja uma floresta com cinco unidades de manejo e dez prescrições, então, uma solução será:

$$V(x) = (\begin{array}{|c|c|c|c|c|} \hline 5 & 1 & 9 & 9 & 3 \\ \hline \end{array})$$

Nesta representação a prescrição 5 corresponde ao manejo adotado na unidade de manejo 1 , a prescrição 1 foi adotada na unidade de manejo 2 e assim por diante até n unidades de manejo.

3.3 - Função de avaliação

A função de avaliação utilizada no problema pode ser definida como maximização do valor presente líquido global ou pela minimização do custo médio de produção, para exemplo seguiremos com a maximização. As penalidades impostas referem-se a variação volumétrica acima ou abaixo da demanda estabelecida, áreas com cortes adjacentes no mesmo período e regulação da produção ao final do horizonte de planejamento:

$$f(x) = \sum_{i=1}^m \sum_{j=1}^n C_{ij} X_{ij} - \alpha (D_k - \sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij})^2 - \beta (\sum_{k=0}^{h-1} y_i)^2 - \gamma (R_1 - \sum_{i=1}^m A_i X_{ij})^2$$

em que :

C_{ij} = Valor presente líquido associado a unidade de manejo i , manejada segundo a prescrição j ;

X_{ij} = são variáveis de decisão, representando a j -ésima prescrição de manejo adotada na i -ésima unidade de manejo;

V_{ijk} = e o volume (m3) produzido, no período k , pela i -ésima unidade de manejo adotando-se a j -ésima prescrição de manejo;

α, β, γ = coeficientes de penalidades associados a cada restrição.

D_k = demanda volumétrica no k -ésimo período do horizonte de planejamento

R_1 = área regulatória

A_i = área da unidade de manejo i

y_i = somatório das áreas das unidades de manejo adjacentes cortadas no mesmo período

A restrição espacial de adjacência também foi penalizada utilizando o IAC , sendo representada da seguinte forma:

$$f(x) = \sum_{i=1}^m \sum_{j=1}^n C_{ij} X_{ij} - \alpha (D_k - \sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij})^2 - \beta ((\sum_{i=1}^m \sum_{j=1}^n C_{ij} X_{ij}) (\frac{\sum_{k=0}^{h-1} \sum_{i=1}^m A_i^2 (\frac{1}{d_i})^2}{\sum_{i=1}^m A_i}))^2 - \gamma (R_1 - \sum_{i=1}^m A_i X_{ij})^2$$

3.4 - Preparando o arquivo de dados.

Uma planilha de dados de entrada xlsx para o sistema foi assim definida:

Tabela 4 – Informações necessárias para a planilha dados.

Informação	Quantidade
------------	------------

Número de unidades de manejo	91
Prescrições por unidade de manejo	72
Idade Regulatória (anos)	6
Horizonte de planejamento (anos)	19

Uma segunda planilha é a matriz de **Prescrições** que possui as informações de cadastro das unidades de manejo. Na (Tabela 5) estão exemplificadas 10 prescrições j ($j=1,2...N$) por unidade de manejo i ($i=1,2...M$), informações de cadastro como talhão, área, idade, regime atual, distância do patio, declividade, genótipo, além das informações de custos totais, receitas totais, VPL, custos de colheita, custos de baldeio, custos de transporte, custos de silvicultura, custo de implantação, custo total até ano 0.

Tabela 5 – Matriz com as prescrições de manejo com os custos e receitas totalizados para cada prescrição e unidade de manejo.

Talhão	Área	Idade	Regime	Distpatio	Declividade	Material Genético	Custos totais	Receitas totais	Vpl	Custos Colheita	Custos Baldeio	Custos Transporte	Custos Silvicultura	Custos Implantação	Custos ate ano 0	Custo Médio de produção
1	2.53	6	af	5.1	12	4	52,412.40	51,869.90	-542.5	28,999.10	1,407.60	2,536.20	10,199.60	7,748.40	1,521.50	78.6103
1	2.53	6	af	5.1	12	4	45,534.10	51,869.90	6,335.90	28,999.10	1,407.60	2,536.20	4,873.70	6,587.90	1,129.50	72.8848
1	2.53	6	af	5.1	12	4	52,177.40	53,609.50	1,432.10	30,041.50	1,454.80	2,621.30	9,182.40	7,355.90	1,521.50	76.5209
1	2.53	6	af	5.1	12	4	46,142.10	53,609.50	7,467.50	30,041.50	1,454.80	2,621.30	4,563.50	6,331.40	1,129.50	71.5720
1	2.53	6	af	5.1	12	4	49,637.30	51,197.90	1,560.50	28,767.10	1,389.40	2,503.40	8,736.90	6,719.00	1,521.50	91.8450
1	2.53	6	af	5.1	12	4	44,050.10	51,197.90	7,147.80	28,767.10	1,389.40	2,503.40	4,447.90	5,812.90	1,129.50	83.0715
1	2.53	6	af	5.1	12	4	48,347.40	50,769.30	2,421.90	28,566.20	1,377.80	2,482.40	7,927.10	6,472.40	1,521.50	76.5528
1	2.53	6	af	5.1	12	4	43,423.40	50,769.30	7,345.90	28,566.20	1,377.80	2,482.40	4,198.00	5,669.50	1,129.50	71.3980
1	2.53	6	af	5.1	12	4	46,922.70	49,108.00	2,185.40	27,645.50	1,332.70	2,401.20	7,705.40	6,316.40	1,521.50	88.9343
1	2.53	6	af	5.1	12	4	42,209.80	49,108.00	6,898.20	27,645.50	1,332.70	2,401.20	4,133.50	5,567.60	1,129.50	80.8155

* Distpatio = distância mínima ao pátio de estoque de madeira ; Vpl = valor presente líquido para a prescrição j por ha; Custos até ano 0= custos considerados antes do início do horizonte de planejamento; Custo médio de produção = custo médio para a produção de 1 m³ de madeira utilizado na opção de minimizar.

Também definimos a matriz **mCorte** (Tabela 6), que é uma matriz binária que informa, do ano zero ao final do horizonte de planejamento, se a unidade de manejo i com a prescrição j sofreu corte (1) ou não (0) no ano k.

Tabela 6 – Matriz indicando possibilidades de corte para cada unidade de manejo i e prescrição j.

Talhão	Prescrição	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1	1	1	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	1	0	0
1	2	1	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	1	0	0
1	3	1	0	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	0	1
1	4	1	0	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	0	1
1	5	1	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0
1	6	1	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0
1	7	1	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	1
1	8	1	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	1
1	9	1	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1
1	10	1	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1

A matriz deve que ter o nome **mCorte** para entendimento do programa. Esta matriz auxilia na construção da restrição de volume e na restrição de adjacência , as colunas talhão e prescrição são meramente ilustrativas .

A matriz **mRegArea** (Tabela 7), contém a informação da área da unidade de manejo i sobre a prescrição de manejo j ,com idade residual. No problema do exemplo foi considerado uma idade regulatória de 6 anos.

Tabela 7 – Matriz com as informações de área para cada classe de idade residual.

Talhão	Prescrição	Área1	Área2	Área3	Área4	Área5	Área6
1	1	0	0	2.53	0	0	0
1	2	0	0	2.53	0	0	0
1	3	2.53	0	0	0	0	0
1	4	2.53	0	0	0	0	0
1	5	0	0	2.53	0	0	0
1	6	0	0	2.53	0	0	0
1	7	2.53	0	0	0	0	0
1	8	2.53	0	0	0	0	0
1	9	2.53	0	0	0	0	0
1	10	2.53	0	0	0	0	0

Outra matriz definida para construção do sistema é a **mVolume** (Tabela 8) que fornece as informações de volume total em cada ano k do horizonte de planejamento ao assinalar a alternativa de manejo j.

Tabela 8 – Matriz com as informações de volume total (m³) por unidade de manejo i e prescrição j.

Talhão	Prescrição	0.0	1.0	2.0	3.0	4.0	5.0	6.0	7.0	8.0	9.0	10.0	11.0	12.0	13.0	14.0	15.0	16.0	17.0	18.0
1	1	610.8	0.0	0.0	0.0	610.8	0.0	0.0	0.0	610.8	0.0	0.0	0.0	610.8	0.0	0.0	0.0	610.8	0.0	0.0
1	2	610.8	0.0	0.0	0.0	610.8	0.0	0.0	0.0	610.8	0.0	0.0	0.0	610.8	0.0	0.0	0.0	610.8	0.0	0.0
1	3	610.8	0.0	0.0	0.0	0.0	809.4	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	809.4	0.0	0.0	0.0	610.8
1	4	610.8	0.0	0.0	0.0	0.0	809.4	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	809.4	0.0	0.0	0.0	610.8
1	5	610.8	0.0	0.0	0.0	0.0	0.0	988.2	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	0.0	988.2	0.0	0.0
1	6	610.8	0.0	0.0	0.0	0.0	0.0	988.2	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	0.0	988.2	0.0	0.0
1	7	610.8	0.0	0.0	0.0	0.0	0.0	0.0	1126.6	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	0.0	0.0	1126.6
1	8	610.8	0.0	0.0	0.0	0.0	0.0	0.0	1126.6	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	0.0	0.0	1126.6
1	9	610.8	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1221.7	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	0.0	988.2
1	10	610.8	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1221.7	0.0	0.0	0.0	610.8	0.0	0.0	0.0	0.0	0.0	988.2

Outras duas matrizes definidas par o sistema computacional foram a **mAdj** e a **mDistancia**. A matriz **mAdj** (Tabela 9) é uma matriz binária de tamanho $n \times n$ onde o valor um é assinalado se o talhão i for vizinho do talhão ii e zero caso contrário, esta é a matriz ordinária de adjacência (MAO), ela pode ser criada com ajuda de um SIG, no Arcgis por exemplo existe uma função que se chama `polygonneighborhood` que retorna esta matriz.

Tabela 9 – Matriz contento a informação de unidades de manejo adjacentes.

Talhão(i)	1	2	3	4	5	6	7	...	n
1	0	1	0	0	0	0	0	0	0
2	1	0	1	0	0	0	0	0	0
3	0	1	0	1	0	0	0	0	0
4	0	0	1	0	1	0	0	0	0
5	0	0	0	1	0	1	0	0	0
6	0	0	0	0	1	0	1	0	0
7	0	0	0	0	0	1	0	1	0
...	0	0	0	0	0	0	1	0	1
N	0	0	0	0	0	0	0	1	0

A matriz **mDistancia** (Tabela 10) possui as distâncias de cada unidade de manejo i até a unidade de manejo ii . Estas distâncias são utilizadas no cálculo do IAC, que é utilizado como penalidade na função de avaliação.

Tabela 10 – Matriz com as distâncias de cada unidade de manejo i , a unidade de manejo ii .

Talhão(i)	1	1	1	1	1	1	1	1	1	1
ii	1	2	3	4	5	6	7	8	9	10
Distância	0.0	275.8	539.3	275.8	40.0	263.5	539.3	263.5	8.0	1202.6

Para exemplificar o uso das meta-heurísticas implementadas, foi definida uma fazenda modelo, denominada fazenda cajamarca, destinada a produção de madeira para uma fábrica de celulose, com uma área de efetivo plantio de 1.892,08 ha. O horizonte de planejamento utilizado foi de 18 anos, a área média de cada unidade de manejo 20,8 ha. O problema proposto consiste em manejar a floresta para a produção de madeira para celulose, com espaçamento de plantio 3x3m, um ciclo de dois cortes, com regimes de

alto-fuste (AF) e primeira talhadia (TA) para fins de estabelecer as prescrições de manejo. As rotações consideradas foram 5 a 9 anos para ambos os regimes de corte. A idade regulatória definida foi de 6 anos.

O objetivo do manejo foi maximizar o valor presente líquido durante o horizonte de planejamento, a uma taxa de descontos de 10% ao ano, sujeito as restrições de produção, regulação e de adjacência. A distribuição inicial das classes de idade da floresta encontra se na Figura 10.

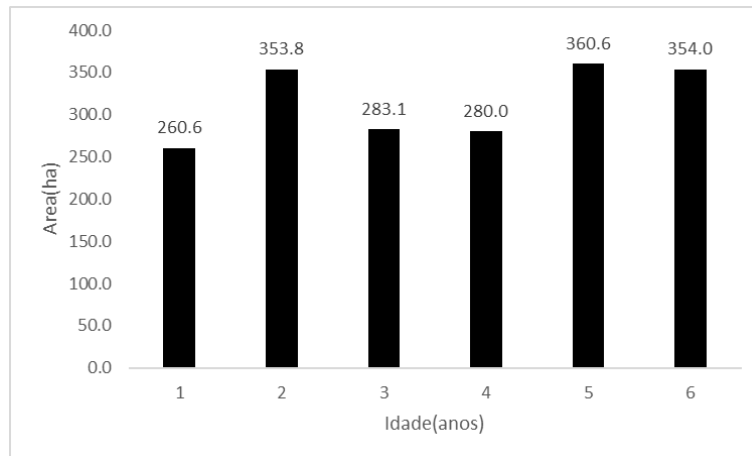


Figura 10– Distribuição inicial de classes de idade encontrada na fazenda modelo.

4- Resultados e Discussão

A tela inicial do sistema é apresentada na Figura 11.

Iniciando a interface:

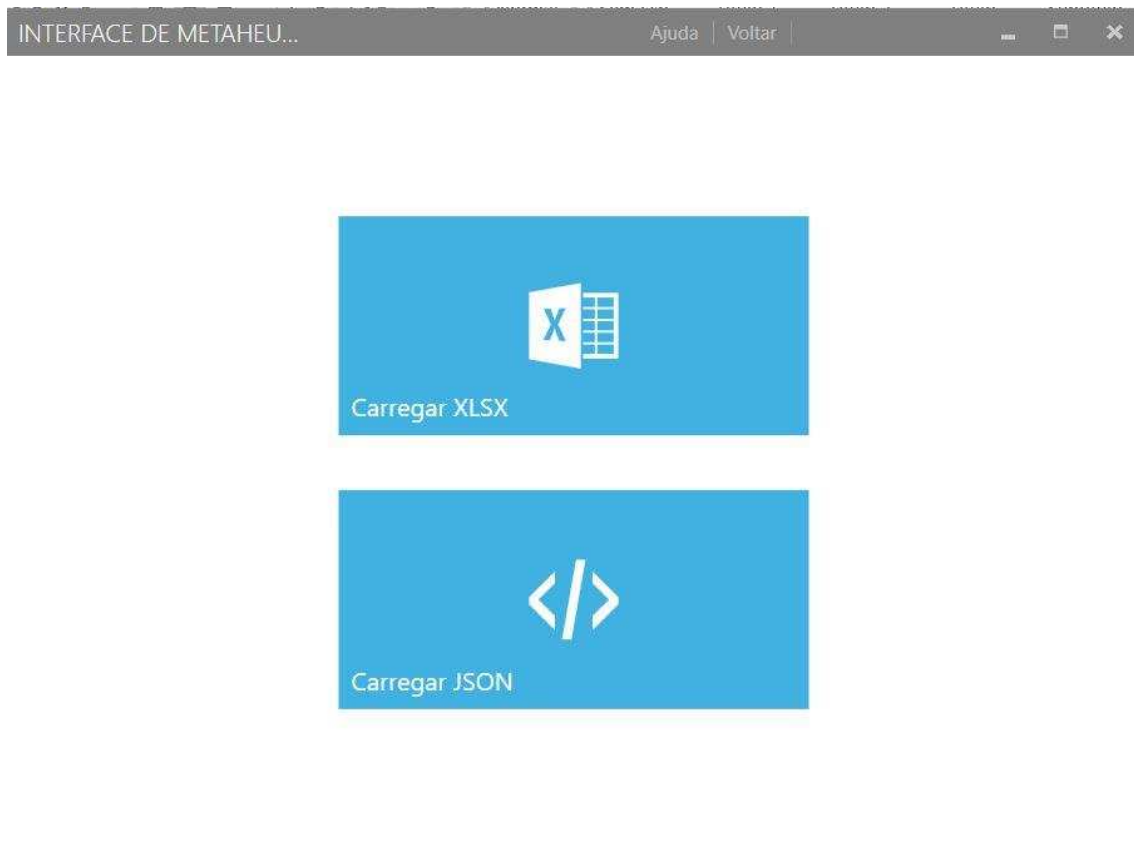


Figura 11– Tela inicial do sistema.

Após preparar as planilhas com as matrizes referentes ao modelo de planejamento inicia-se a interface, sendo a importação dos dados feita no formato xlsx ou json. Como exemplo iremos utilizar o formato xlsx. Clicando em **Carregar Xlsx**, a tela para

selecionar o arquivo contendo as planilhas descritas no item anterior é aberta, como exemplificado na Figura 12.




Figura 12 - Selecionando o arquivo.xlsx contendo as planilhas para resolução do problema.

Ao selecionar a planilha com os dados é apresentada uma tela para seleção da meta-heurística a ser utilizada, e sua configuração. Na Figura 13 é ilustrada a tela inicial após carregar as informações do problema.

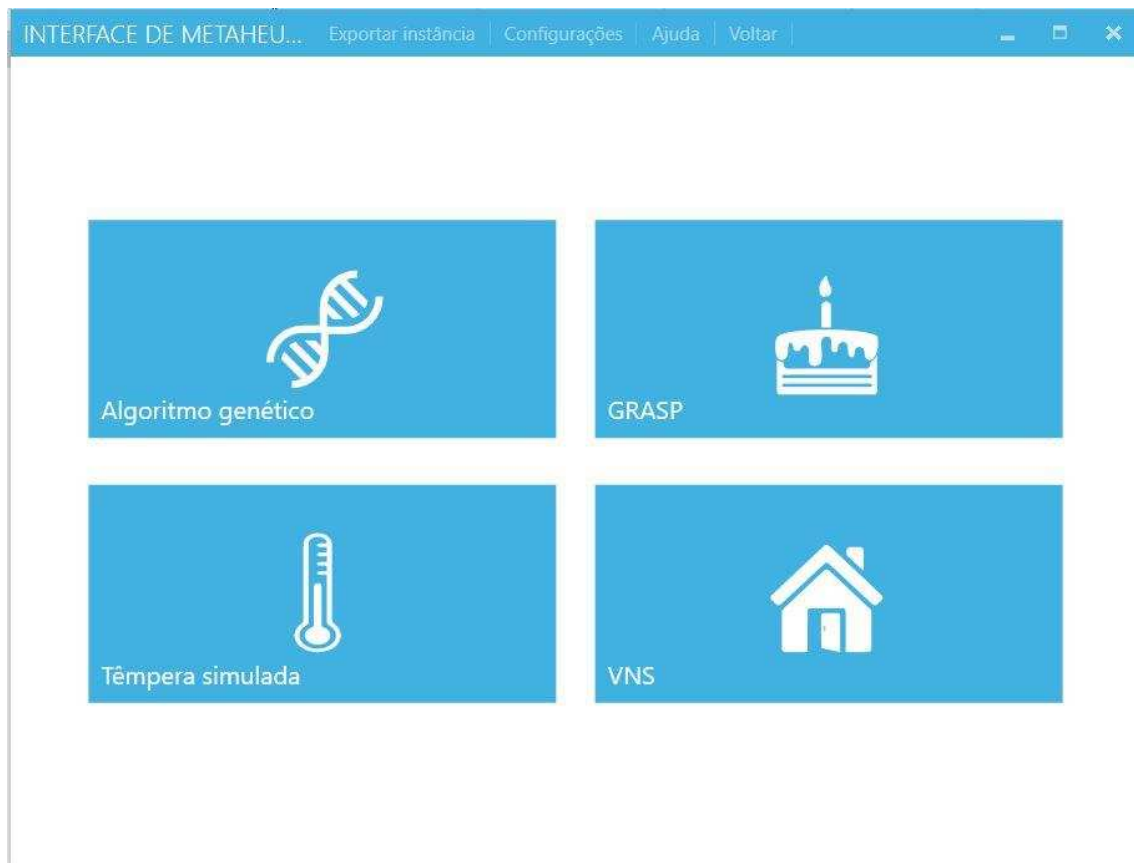


Figura 13 - Tela para seleção das meta-heurísticas e configuração dos parâmetros do problema.

Antes de resolver o problema é preciso determinar algumas restrições. Estas restrições são determinadas nas configurações. A Figura 14 ilustra a tela inicial de configurações.

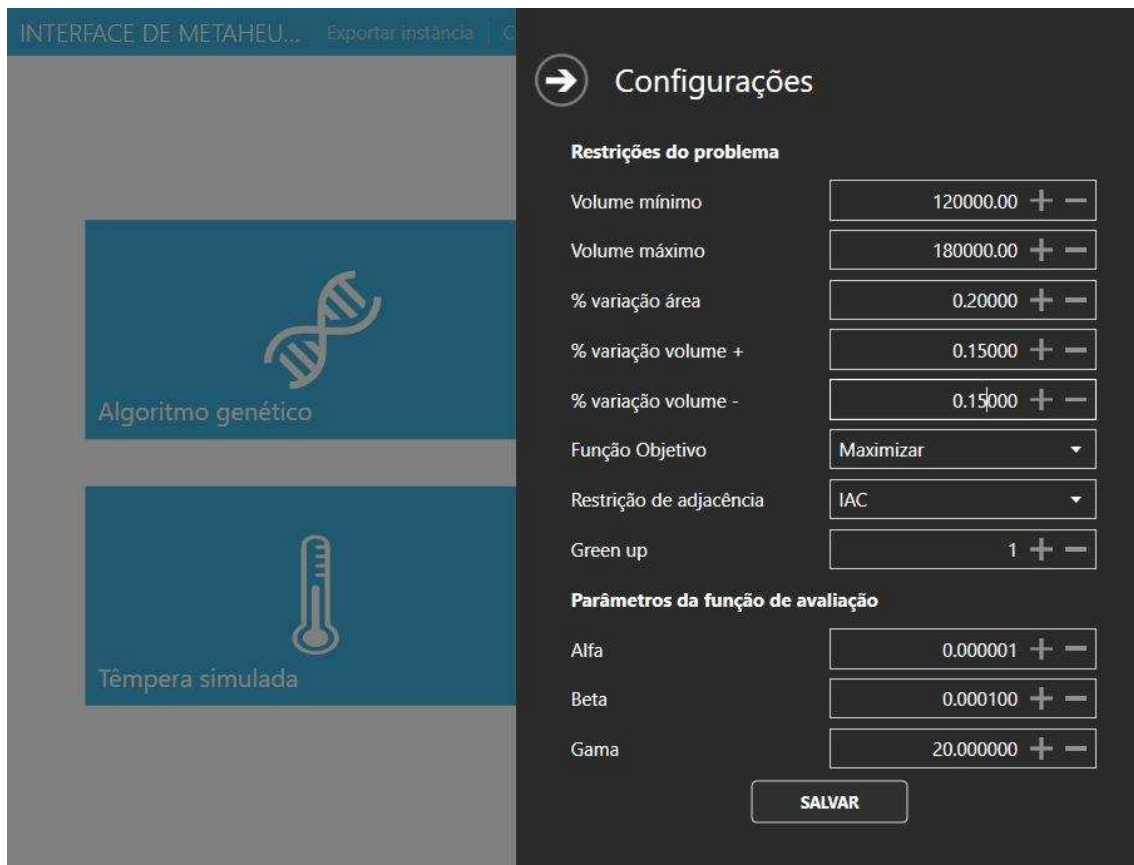


Figura 14– Restrições do problema e parâmetros da função de avaliação.

Nas restrições devem ser informados os volumes mínimo e máximo de madeira que estão relacionadas às restrições 3 e 4 do modelo matemático. Outra restrição que precisa ser definida é a de regulação, (restrições 7 e 8 do modelo matemático), que permite definir um limite de variação para a área regulatória. Ainda, relacionado a restrição de volume, existe a restrição que não permite a variação do volume em anos seguintes, sendo possível estabelecer volumes crescentes ou decrescentes ao longo do horizonte de planejamento, (restrições 5 e 6 do modelo matemático).

A restrição de adjacência pode ser utilizada de duas formas na função de avaliação. Como definido anteriormente o usuário tem a opção de escolher se deseja penalizar pelo somatório das áreas adjacentes com corte no mesmo período ao quadrado, ou através do IAC ao quadrado.

Outra restrição que precisa ser definida é o período em que uma unidade de manejo adjacente, precisa ficar sem intervenção. Como exemplo foi utilizado o período de um ano.

Após definir as restrições, é necessário calibrar os parâmetros da função de avaliação. Esses valores são utilizados para convergência da função. O parâmetro alfa (α)

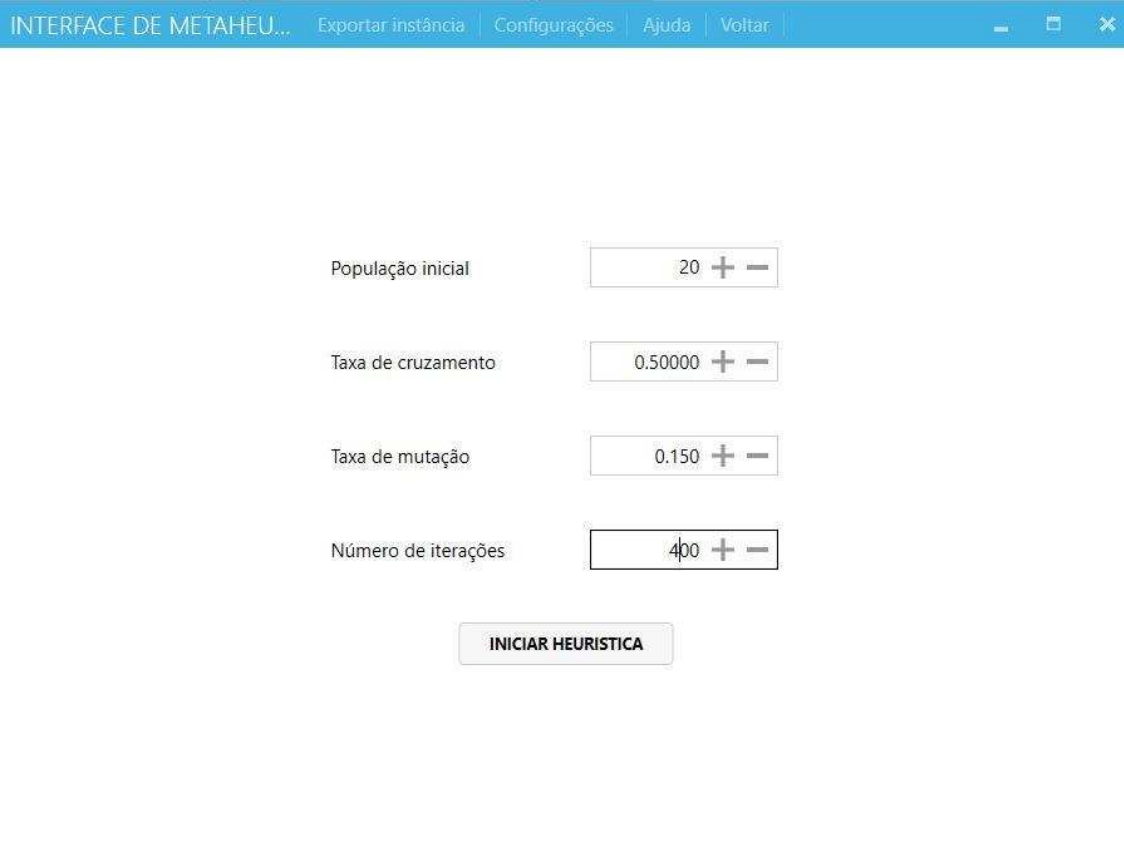
está relacionado com as penalidades volumétricas, beta (β) com as penalidades de adjacência e gama (γ) com a penalidade de área regulatória.

Após formular o problema, o passo seguinte é sua resolução. Utilizamos as seguintes configurações para exemplificar: demanda mínima 120.000 m³ e demanda máxima 180.000 m³ de madeira, variação de 15% do volume colhido durante os períodos do horizonte de planejamento, variação de 20% na área regulada, idade regulatória de 6 anos, IAC para restrição de adjacência e um período de green up igual a um.

4.1 - Meta-Heurísticas implementadas

4.1.1 - Algoritmo Genético (AG)

Definidas as configurações das restrições do problema em estudo, o usuário pode selecionar a meta-heurística de interesse, configurar os parâmetros e encontrar uma solução para o problema. Iniciaremos ilustrando a meta-heurística AG, com os parâmetros que são ilustrados na Figura 15.



População inicial	20 + -
Taxa de cruzamento	0.50000 + -
Taxa de mutação	0.150 + -
Número de iterações	400 + -

INICIAR HEURISTICA

Figura 15 - Parâmetros da meta-heurística algoritmo genético.

O AG depende de uma população de soluções candidatas. O tamanho da população, que geralmente é um parâmetro especificado pelo usuário, é um fator importante que afeta o desempenho do AG. Uma população pequena pode levar a uma convergência prematura e a soluções de baixa qualidade. Por outro lado, grandes populações levam a gastos desnecessários de recursos computacionais (SASTRY et al., 2014).

A população inicial é gerada com os indivíduos que tenham a função de avaliação maior que zero, existindo um filtro inicial para gerar soluções boas. A população estará completa quando atingido o número de pais determinado pelo parâmetro população inicial, neste exemplo 20 indivíduos. Para a interface utilizamos a seleção proporcional e o método da roleta viciada para a seleção dos pais, que foi descrito no Capítulo 1.

Após a seleção, os indivíduos do grupo de reprodução são recombinados, para criar novos indivíduos e melhores descendentes. A taxa de crossover utilizada pela interface é a de um ponto, onde a ruptura é feita a uma porcentagem determinada pelo usuário.

Se for utilizado um operador de crossover, como o crossover de um ponto, na maioria das vezes é possível ter melhores cromossomos, porém, se os dois pais tiverem o mesmo alelo em um determinado gene, um ponto de cruzamento não iria mudar isso. Em outras palavras, esse gene teria o mesmo alelo para sempre. Para superar isso a mutação é realizada, a fim de acrescentar diversidade à população (SASTRY et al., 2014). Há efeitos de interação entre os parâmetros, o que implica que eles não podem ser considerados separadamente (LU e ERIKSSON, 2000).

O critério de parada utilizado pelo algoritmo é o número de vezes que ocorreria o processo de seleção e cruzamento dos pais, sem melhora na população.

Utilizamos uma população inicial de 20 indivíduos, uma taxa de crossover de 50%, e taxa de mutação de 15%. O critério de parada foi o número de iterações sem melhorar a solução definido como 400.

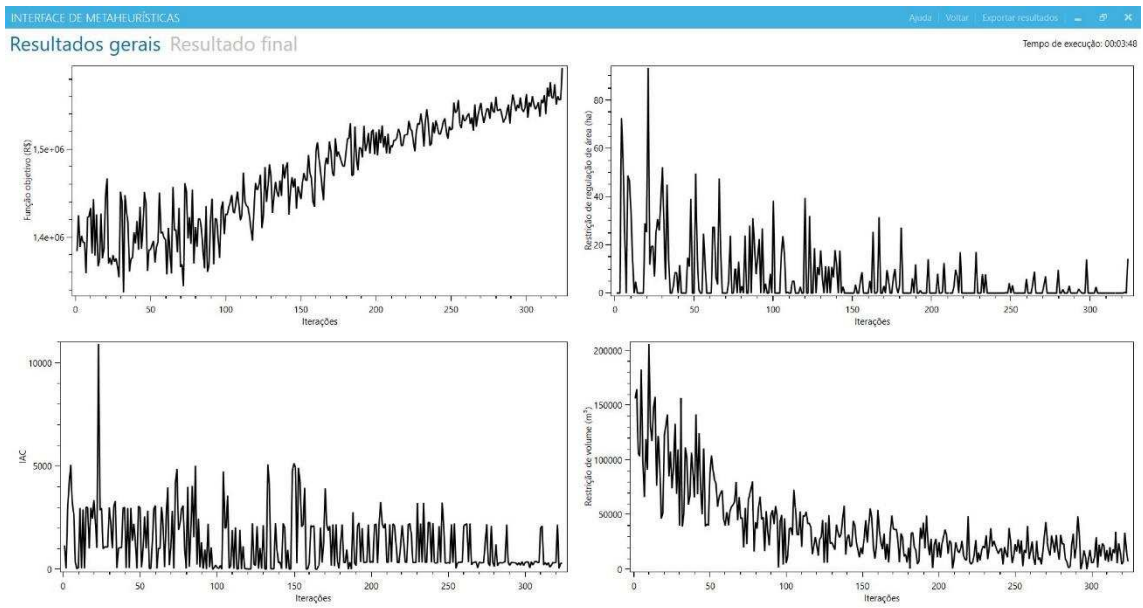


Figura 16 – Resultados gerais , função objetivo e o comportamento das penalidades de restrição , IAC e volumétrica, com o passar das iterações.

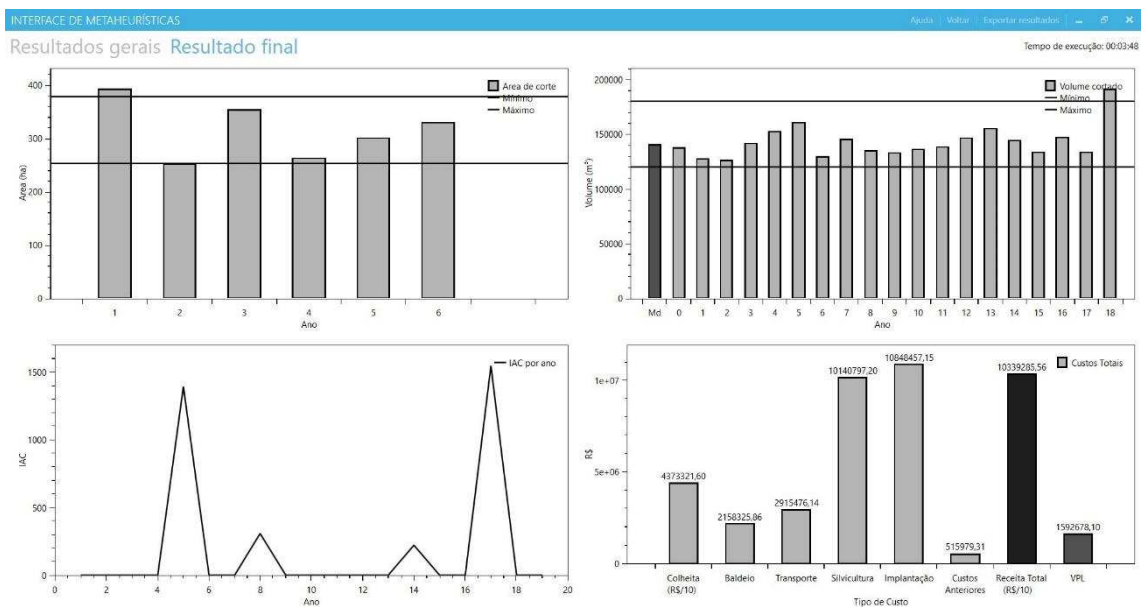


Figura 17 – Resultados finais com a área regulada, o volume a ser cortado e o IAC por período além dos custos e o VPL acumulado.

No exemplo (Figuras 16 e 17), o VPL global foi de 1.592.678,10, a penalidade na restrição de regulação foi de 1,90 ha e a penalidade de volume foi de 7.211,43 m³, durante todo horizonte de planejamento. A restrição de adjacência não foi atendida em todos os anos e o volume total produzido foi de 2.718.272,00 m³, com um tempo de 3 minutos e 48 segundos.

Para salvar os resultados basta clicar em exportar os resultados e salvar o resultado em uma planilha xlsx. A Figura 18 ilustra este passo. Existe também a possibilidade de salvar as imagens, ficando a critério do usuário da interface.

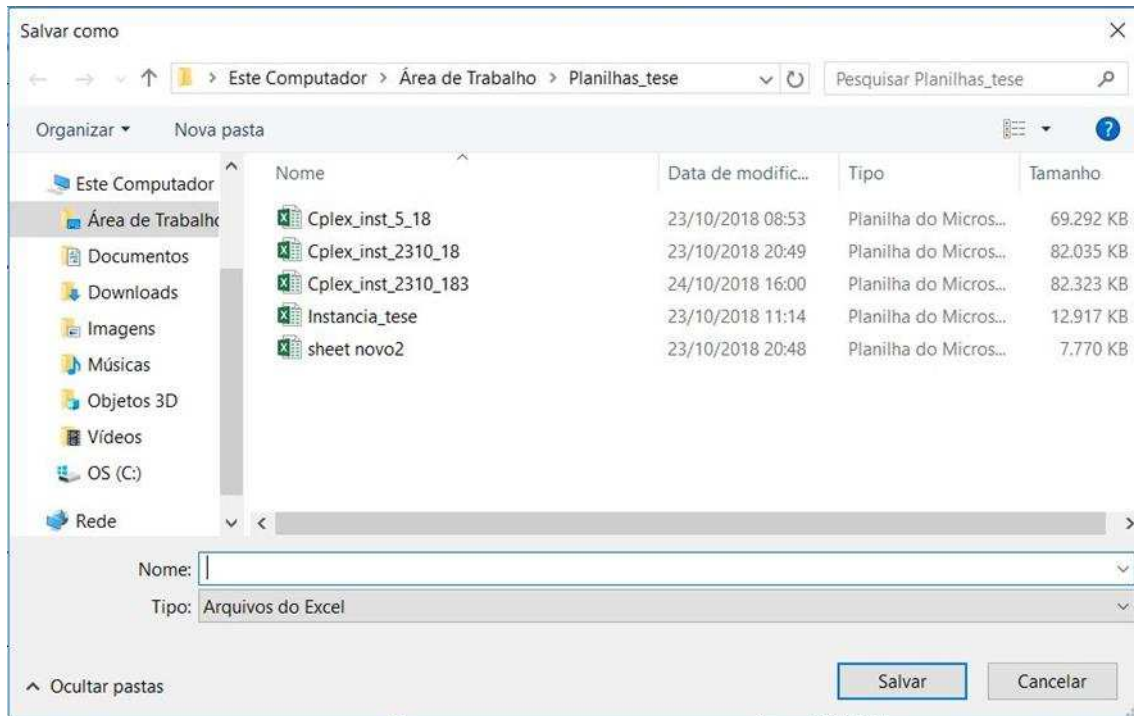


Figura 18 – Salvando os resultados para o algoritmo genético

4.1.2 - Greedy Randomized Adaptive Search Procedures (Procedimentos de Busca gulosa aleatórios e adaptativos)

A meta-heurística Greedy Randomized Adaptive Search Procedures (GRASP) é uma heurística gananciosa iterativa para resolver problemas de otimização combinatória (TALBI, 2009). Foi introduzida em 1989 por Feo e Resende para resolver problemas de cobertura de conjuntos. É um processo multi-start ou iterativo, em que cada iteração GRASP consiste em duas fases, uma fase de construção, em que uma solução viável é produzida, e uma fase de busca local, em que é procurado um ótimo local na vizinhança da solução construída (FESTA E RESENDE, 2009). O componente probabilístico do

GRASP é caracterizado pela escolha aleatória de uma das melhores soluções candidatas na lista, mas não necessariamente a melhor solução (FEO E RESENDE, 1995).



Figura 19 – Parâmetros da meta-heurística Grasp.

O parâmetro alfa ($\alpha \in [0,1]$), define o compromisso entre a exploração da busca , intensificação e diversificação, quando alfa é igual a um , é um algoritmo guloso determinístico, quando alfa é igual a zero é um algoritmo guloso aleatório , pequenos valores de alfa geram mais elementos na lista restrita de candidatas (TALBI , 2009).

O método de escolha para construir a lista restrita de candidatos (LRC), pode ser limitado pelo número de elementos (baseado em cardinalidade) ou por sua qualidade (baseada em valor). No primeiro caso, é feito a seleção dos p elementos com os melhores custos incrementais, onde p é um parâmetro. Já o segundo método está associado a um parâmetro limiar $\alpha \in [0,1]$. A LRC é formada por todos os elementos possíveis e $e \in E$ que podem ser inseridos na solução parcial em construção sem destruir viabilidade e cuja qualidade é superior para o valor limite, isto é, $c(e) \in [c_{\min}, c_{\min} + \alpha (c_{\max} - c_{\min})]$ (TALBI, 2009).

Existem três opções para fazer a busca local realizada após a fase construtiva, esta pode ser feita com 1-opt, onde apenas uma posição do vetor é alterada, e o 2-opt, onde

duas posições do vetor são alteradas de uma vez. Existe também a opção de utilizar a meta-heurística VNS para fazer a fase de busca local.

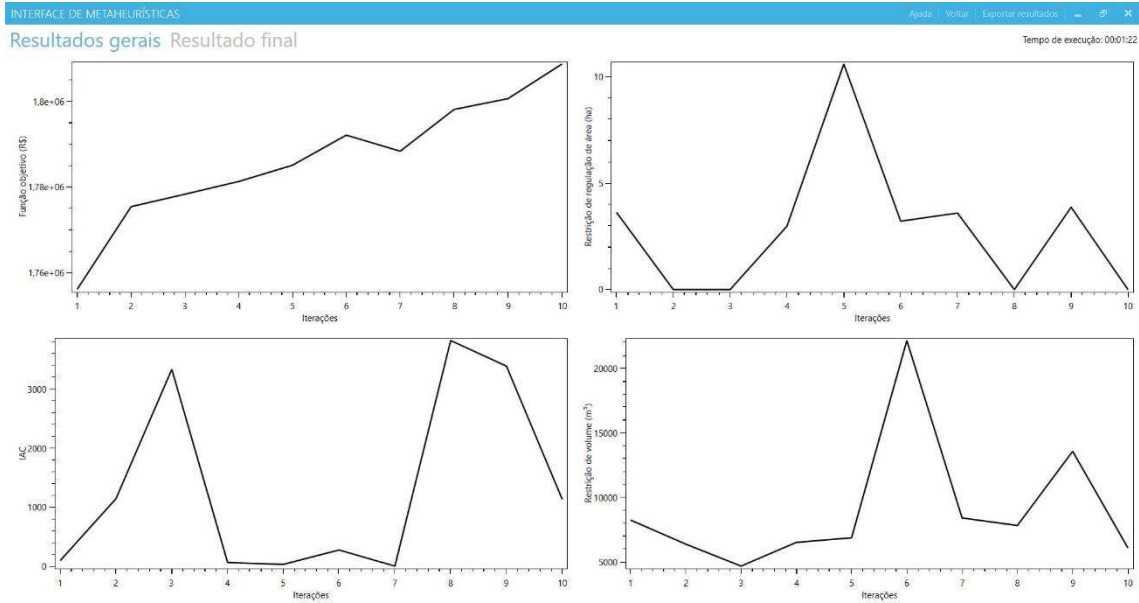


Figura 20 – Resultados gerais , função objetivo e o comportamento das penalidades de regulação , IAC e volumétrica, com o passar das iterações do algoritmo.

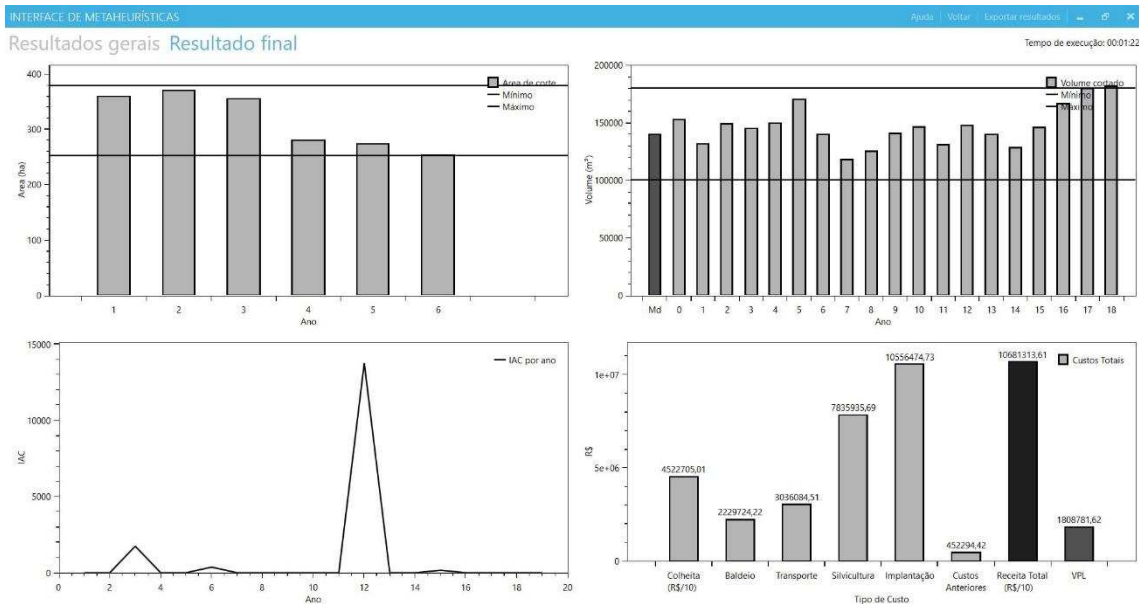


Figura 21 - Resultados finais com a área regulada, o volume e o IAC por período além do VPL e dos custos acumulados.

Observando os resultados das (Figuras 20 e 21), obtivemos um VPL de 1.808.781,62, não houve penalidade na restrição regulação, e a penalidade na restrição de volume foi de 6.066,19 m³, durante todo horizonte de planejamento, a restrição de

adjacência não foi atendida em todos os anos, no período 3 e 12 tivemos unidades de manejo vizinhos cortados no mesmo ano. O volume total produzido foi de 2.793.027,31 m³, o tempo de processamento foi de 1 minuto e 22 segundos.

4.1.3 - Simulated annealing (Recozimento Simulado)

No início dos anos 80, Kirkpatrick et al. (1983) e Cerný (1985) introduziram o conceito de recozimento em problemas de otimização combinatória. Originalmente este conceito foi inspirado por uma analogia entre o processo de recozimento de sólidos e o problema de resolver grandes problemas de otimização combinatória (AARTS et al., 2005). Para ilustrar a aplicação da meta-heurística SA utilizamos o exemplo hipotético descrito no início deste capítulo. Na Figura 22 estão os parâmetros necessários para a execução do algoritmo.

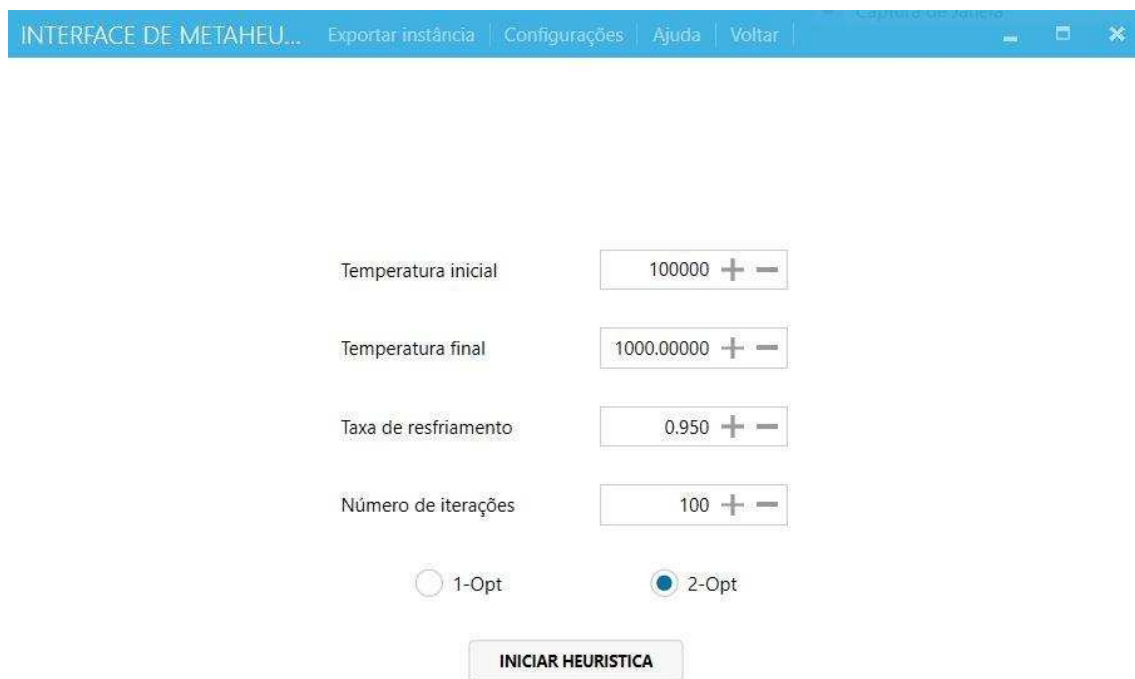


Figura 22 – Parâmetros da meta-heurística Simulated annealing.

A temperatura inicial tem um papel importante na convergência do algoritmo. Temperaturas iniciais altas permitem uma busca aleatória pelo espaço de busca enquanto temperaturas iniciais baixas tendem a convergir para a primeira solução encontrada. A

temperatura final é a temperatura de parada do algoritmo. A taxa de resfriamento utilizada é a geométrica, onde:

$$\text{Temperatura} = T_0 t_r$$

em que T_0 é a temperatura inicial e t_r é a taxa de resfriamento definida.

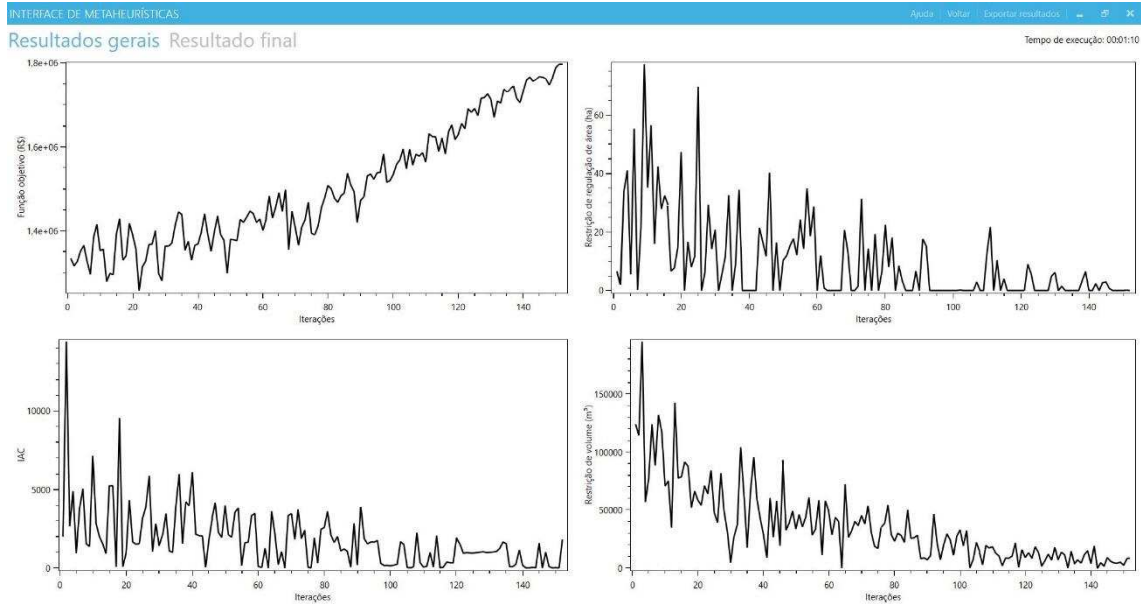


Figura 23 - Resultados gerais , função objetivo e o comportamento das penalidades de regulação , IAC e volumétrica, com o passar das iterações.

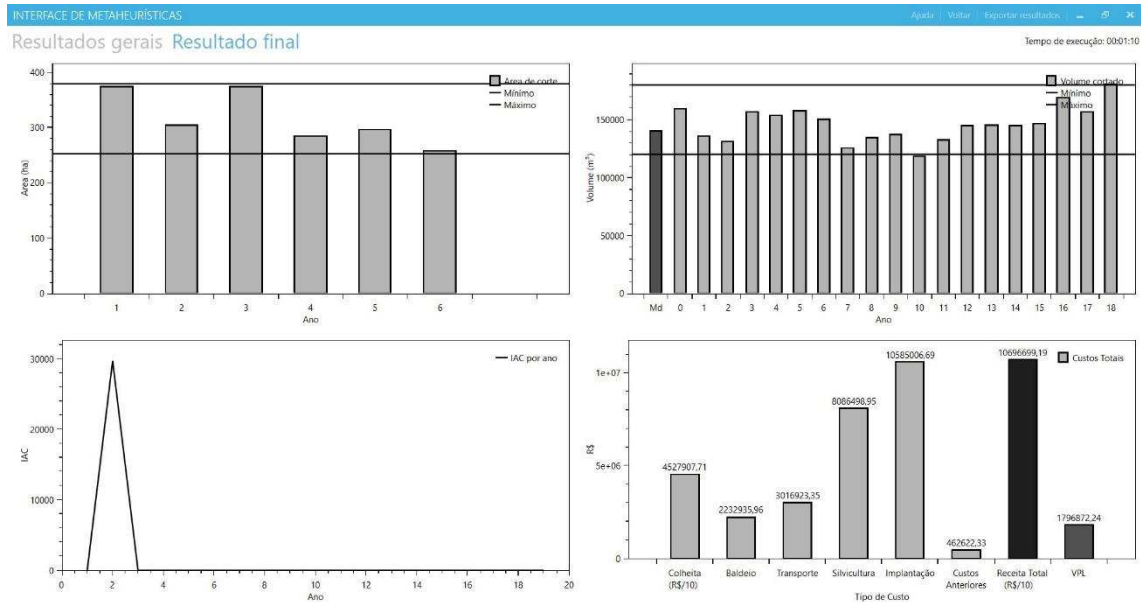


Figura 24 - Resultados finais com a área regulada, o volume e o IAC por período além do VPL e custos acumulados.

Analisando as (Figuras 23 e 24) observa-se um valor de 1.796.872,24 para a função de avaliação, sem penalidade para a restrição de regulação. O IAC foi alto somente no ano 2, com a penalidade de volume de 8.535,6 m³. O volume colhido foi de 2.783.203,166 m³ durante o horizonte de planejamento, com um tempo de um 1 minuto e 10 segundos.

4.1.4 - Variable Neighborhood Search (Pesquisa de vizinhança variável)

Uma mudança sistemática de vizinhança dentro de um algoritmo de busca local produz uma meta-heurística simples e eficaz para otimização combinatória e global, chamada de busca de vizinhança variável (VNS), (HANSEN; MLADENOVIC, 2001). VNS é uma meta-heurística, que explora sistematicamente a ideia de mudança de vizinhança, tanto em descida a mínimos locais ou na fuga de vales (TALBI, 2009). Como um ótimo local dentro de alguma vizinhança não é necessariamente um ótimo local em outra vizinhança, a mudança de vizinhança pode ser realizada durante a fase de busca

local (HANSEN; MLADENOVIC, 2001). O único parâmetro a ser definido é o número de iterações que o algoritmo vai realizar em cada vizinhança.



Figura 25 – Parâmetros da meta-heurística VNS.

Existem três tipos de busca nas vizinhanças $k=3$, a primeira é 1-opt, onde uma unidade de manejo é alterada a cada iteração, a segunda é o 2-opt onde 2 unidades de manejo são alteradas a cada iteração, e a terceira é um procedimento aleatório.

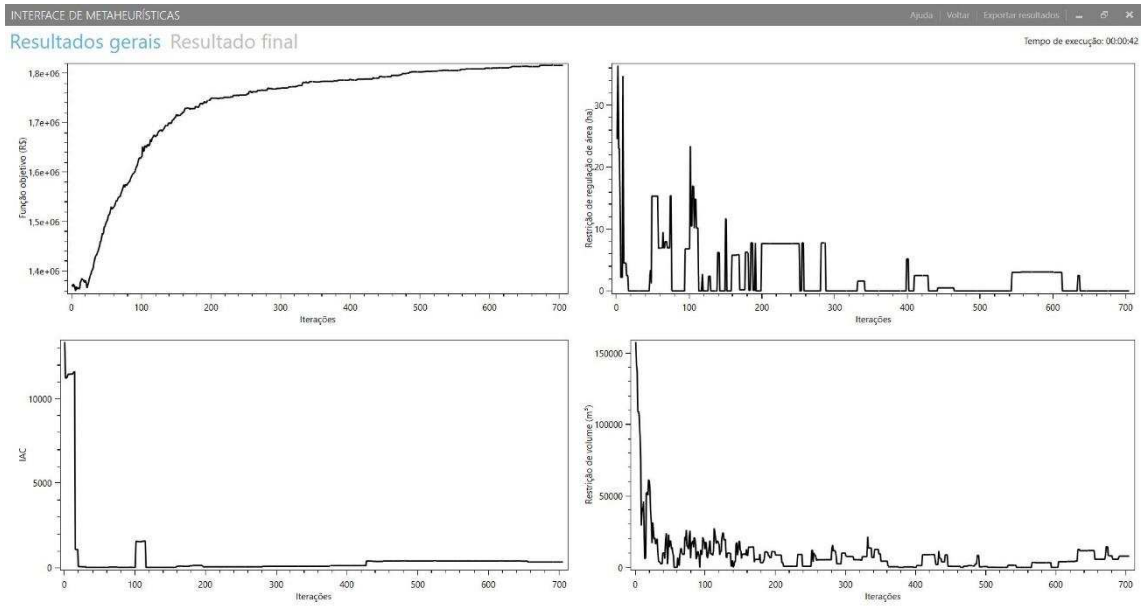


Figura 26 - Resultados gerais , função objetivo e o comportamento das penalidades de regulação , IAC e volumétrica, com o passar das iterações.

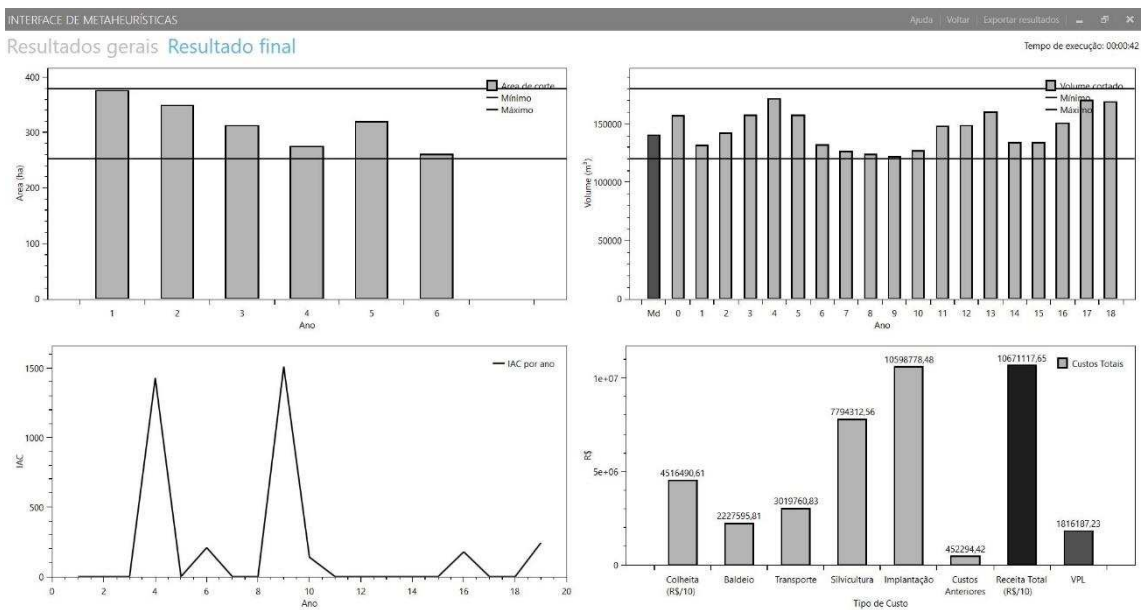


Figura 27 - Resultados finais com a área regulada, o volume e o IAC por período além dos custos acumulados.

Analisando a Figuras 26 e 27, observamos que o tempo de processamento para esta instância foi de aproximadamente 42 segundos, com um valor da função de avaliação de 1.816.187.23, e um volume total colhido de 2.761.464,59 m³. Não houve penalidade para a restrição de regulação. A penalidade volumétrica foi de 7.798,45 m³.

A Tabela 11 foi elaborada com as informações de cada meta-heurística para a instância hipotética desenvolvida.

Tabela 11 – Resumo dos resultados das meta-heurísticas

Meta-heurística	Tempo de processamento	F.A	Volume total Colhido m ³	P.R	P.V
VNS	42seg	1.816.187,23	2.761.464,59	0,00	7.798,45
AG	03min e 48 seg	1.592.678,10	2.718.272,00	14,26	7.211,43
SA	1min e 10 seg	1.796.872,24	2.783.203,17	0,00	8.535,60
GRASP	01min e 22 seg	1.808.781,62	2.793.027,31	0,00	6.066,19

5 - Considerações Finais

A interface gerada é de fácil utilização e as meta-heurísticas desenvolvidas geram bons resultados, com destaque para a SA, GRASP e a VNS.

Há grande possibilidade de expansão da interface, como a implementação de mais restrições, geração de novos gráficos para melhor controle das áreas, custos, desenvolver novas meta-heurísticas e adicionar novas técnicas de busca nas meta-heurísticas existentes.

6 - Referências Bibliográficas

AARTS, E.; KORST, J. ; MICHIELS, W. Simulated annealing. **In Search methodologies** p. 265-285. Springer, Boston, MA. 2014.

BACHMATIUK, J.; GARCIA-GONZALO, J.; BORGES, J.G. Analysis of the performance of different implementations of a heuristic method to optimize forest harvest scheduling. **Silva Fennica**, v.49, n.4, p.1-18. 2015.

BETTINGER, P.; SESSIONS, J.; BOSTON, K. Using tabu search to schedule timber harvests subject to spatial wildlife goals for big game. **Ecological Modelling**, v.94, n.2-3, p.111-123. 1997.

BINOTI, D.H.B.; DA SILVA BINOTI, M.L.M.; LEITE, H.G.; GLERIANI, J.M.; CAMPOS, J.C.C. Regulation of even-aged forest with adjacency constraints. **Forest policy and economics**, v.20, n.1, p.49-57. 2012.

BINOTI, D.H.B.; BINOTI, M.L.M.D.S; LEITE, H.G.; GLERIANI, J.M.; OLIVEIRA, M.L.R.D.; CAMPOS, J.C.C.; SOUZA, A.L.D.; RIBEIRO, C.A.Á.S. Regulação de florestas equiâneas com restrição de classes de idade por compartimento. **CERNE**, v.20, n.4. p. 567-573, 2014.

BORGES, P.; BERGSENG, E.; EID, T. Adjacency constraints in forestry-A simulated annealing approach comparing different candidate solution generators. **Mathematical and Computational Forestry & Natural Resource Sciences**, v.6, n.1, p.11-25. 2014.

CARO, F.; CONSTANTINO, M.; MARTINS, I.; WEINTRAUB, A. A 2-opt tabu search procedure for the multiperiod forest harvesting problem with adjacency, greenup, old growth, and even flow constraints. **Forest Science**, v.49, n.5, p.738-751.2003.

DONG, L.; BETTINGER, P.; LIU, Z.; QIN, H. A comparison of a neighborhood search technique for forest spatial harvest scheduling problems: A case study of the simulated annealing algorithm. **Forest Ecology and Management**, v.356, p.124-135. 2015.

DONG, L.; BETTINGER, P.; QIN, H.; LIU, Z. Reflections on the number of independent solutions for forest spatial harvest scheduling problems: a case of simulated annealing. **Silva Fennica**, v.52, n.1. 2018.

GOMIDE, L.R.; ARCE, J.E.; DA SILVA, A.C.L. Comparação entre a meta-heurística simulated annealing e a programação linear inteira no agendamento da colheita florestal com restrições de adjacência. **Ciência Florestal**, v.23, n.2, p.449-460. 2013.

FEO, T.A.; RESENDE, M.G., Greedy randomized adaptive search procedures. **Journal of global optimization**, v.6, n.2, p.109-133. 1995.

FESTA, P.; RESENDE, M.G., An annotated bibliography of GRASP–Part I: Algorithms. **International Transactions in Operational Research**, v.16, n.1, p.1-24. 2009.

FOTAKIS, D.G.; SIDIROPOULOS, E.; MYRONIDIS, D.; IOANNOU, K.. Spatial genetic algorithm for multi-objective forest planning. **Forest Policy and Economics**, v.21, p.12-19. 2012.

HANSEN, P.; MLADENOVIC, N., Variable neighborhood search: Principles and applications. **European journal of operational research**, v.130, n.3, pp.449-467. 2001.

GOMIDE, L. R.; ARCE, J. E.; DA SILVA, A. C. L. Uso do algoritmo genético no planejamento florestal considerando seus operadores de seleção. **CERNE**, v.15, n.4, p.460-467. 2009.

LEGÜES, A.D.; FERLAND, J.A.; RIBEIRO, C.C.; VERA, J.R.; WEINTRAUB, A. A tabu search approach for solving a difficult forest harvesting machine location problem. **European Journal of Operational Research**, v.179, n.3, p.788-805. 2007.

LOCKWOOD, C.; MOORE, T. Harvest scheduling with spatial constraints: a simulated annealing approach. **Canadian journal of forest research**, v.23, n.3, p.468-478. 1993.

LU, F.; ERIKSSON, L.O. Formation of harvest units with genetic algorithms. **Forest Ecology and Management**, v.130, n.1, p.57-67. 2000.

MCDILL, M. E.; BRAZE, J. Comparing adjacency constraint formulations for randomly generated forest planning problems with four age-class distributions. **Forest Science**, v.46, p. 423–436, 2000.

MARTELL, D.L.; GUNN, E.A.; WEINTRAUB, A. Forest management challenges for operational researchers. **European journal of operational research**, v.104, n.1, p.1-17. 1998.

ÖHMAN, K.; ERIKSSON, L.O. The core area concept in forming contiguous areas for long-term forest planning. **Canadian Journal of Forest Research**, v.28, n.7, p.1032-1039. 1998.

RODRIGUES, F. L. Meta-heurística e sistema de suporte à decisão no gerenciamento de recursos florestais. Viçosa, MG: UFV, 2001. 225p. **Doutorado em Ciência Florestal** Universidade Federal de Viçosa, Viçosa.

RODRIGUES, F.L.; LEITE, H.G.; SANTOS, H.D.N., SOUZA, A.L.D.; SILVA, G.F.D. Meta-heurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, v.22, n.2, p.233-245. 2004.

SASTRY, K.; GOLDBERG, D.E.; KENDALL, G., Genetic algorithms. **In Search methodologies** (pp. 93-117). Springer, Boston, MA. 2014.

SILVA, G. F.; PIASSI, L. C.; MÔRA, R.; MARTINS, L. T.; TEIXEIRA, A. F.; BARROS JUNIOR, A. A. Meta-heurística algoritmo genético na solução de modelos de planejamento florestal. **Revista Brasileira de Ciências Agrárias**. v.4, n.2, p.160-166. 2009.

TALBI, EL-GHAZALI. **Metaheuristics: from design to implementation**. John Wiley & Sons, 593p. 2009.

THOMPSON, M.P.; HAMANN, J.D.; SESSIONS, J. Selection and penalty strategies for genetic algorithms designed to solve spatial forest planning problems. **International Journal of Forestry Research**, v.2009, Article ID 527392, p.1-14, 2009.

CAPÍTULO 3 – IMPLEMENTAÇÃO DA META-HEURÍSTICA GRASP A UM PROBLEMA DE REGULAÇÃO FLORESTAL COM RESTRIÇÕES DE ADJACÊNCIA.

1- Introdução

A gestão de recursos florestais é a arte e a ciência de tomar decisões com respeito ao uso, conservação e organização de florestas e recursos relacionadas. As florestas podem ser manejadas para a produção de madeira, produção de água e proteção hidrológica, vida selvagem, recreação, ou para múltiplos objetivos (BUONGIORNO; GILLESS, 2003). As metas econômicas ainda são predominantes nos planos de manejo florestais, porém estes planos estão cada vez mais incorporando objetivos ecológicos e sociais, desempenhando papel mais realista na tomada de decisões (BETTINGER et al., 2007; BINOTI et al., 2012).

Modelos matemáticos têm sido utilizados com sucesso na tomada de decisões florestais há décadas. Decisões apoiadas por esses modelos vão desde o planejamento estratégico de longo prazo para agendamento de colheita com horizontes de planejamento de longo prazo até decisões operacionais diárias na colheita e transporte (MARTELL et al., 1998; WEINTRAUB AND MURRAY, 2006).

Os problemas de otimização que envolvem um grande número de alternativas estão sempre presentes nos setores públicos e privados da economia (FEO; RESENDE, 1995). No entanto, na prática, é inviável a enumeração completa das alternativas, uma vez que o número de combinações muitas vezes cresce exponencialmente com o tamanho do problema. A maioria desses problemas são computacionalmente intratáveis por natureza ou suficientemente grandes, o que impede o uso de um algoritmo exato. Nesses casos métodos heurísticos são empregados para encontrar boas soluções, mas sem garantia de ser a solução ótima (FEO; RESENDE, 1995, FESTA; RESENDE, 2009).

Uma preocupação recente com as condições ambientais, como proteção da vida selvagem, redução da erosão, preservação e melhoria da qualidade das águas, adiciona características espaciais explícitas ao planejamento florestal. Regular impactos espaciais da atividade de colheita florestal promove maior sustentabilidade a longo prazo, alcançando estes objetivos minimizando os impactos ambientais, além de proporcionar um habitat desejável para certas espécies. (WEINTRAUB AND MURRAY, 2006).

2 - Objetivos

O objetivo do presente trabalho foi avaliar a implementação e eficiência de uma meta-heurística construtiva, a Greedy Randomized Adaptive Search Procedure (GRASP), para resolução de um problema de regulação florestal com restrições de regulação, produção e adjacência além de avaliar sua eficiência em relação ao método exato. Avaliamos três alternativas de implementação da GRASP, com as seguintes alternativas: a busca local 1-opt, busca local 2-opt e uma abordagem híbrida com a meta-heurística VNS.

3 - Material e Métodos

Uma floresta hipotética foi utilizada como estudo de caso, sendo gerada utilizando um sistema de informações geográficas (SIG). O uso do SIG foi necessário para calcular as distâncias e as vizinhanças de cada unidade de manejo que foram definidas como sendo o talhão. A floresta modelo contém 1.892,08 ha de eucalipto, destinados a produção de celulose. A distribuição das classes de idade e suas respectivas áreas estão apresentados na Figura 28.




Figura 28 – Distribuição inicial das classes de idade da fazenda modelo.

O problema definido é manejar a floresta para os próximos 18 anos, em espaçamento 3x3m, com regimes de corte de alto-fuste (AF) e primeira talhadia (TA). As rotações consideradas foram de 5 a 9 anos para ambos os regimes de corte. A idade regulatória adotada foi de 6 anos. O objetivo definido é maximizar o valor presente

líquido durante todo o horizonte de planejamento, sujeito a restrições de produção, regulação e de adjacência.

3.1 - Produção, receitas e custos.

Para gerar as curvas de crescimento e produção foi considerado apenas um material genético para toda a floresta. Uma equação obtida a partir do ajuste do modelo de Gompertz foi utilizada para prever o crescimento na floresta, sendo:

$$\text{Volume} = 591,3915(1 + 95,1072e^{-0,0815\text{Idade}})^{-1}$$

Para regimes de talhadia foi considerada redução de 20% na produção na idade de corte. A taxa de descontos utilizada foi de 10% a.a. e o valor de venda da madeira em pé foi de R\$/m³ 80,00. Os custos de colheita utilizados seguiram o trabalho de Burla (2008) e foram definidos de acordo com a produtividade. Os custos de baldeio foram extraídos do trabalho de Cardoso Machado e Silva Lopes (2000), foi utilizado um valor médio de R\$/m³1,67. Os custos de transporte, foram obtidos de Tonetto Alves, (2013), sendo considerado um valor médio de R\$/m³/km 0,295.

3.2 - Formulação do problema e métodos utilizados.

Para resolução do método exato os modelos foram codificados na sintaxe do AMPL e resolvidos pelo pacote computacional Cplex 12.5. A formulação do modelo utilizado esta no anexo 1. A meta-heurística GRASP foi implementada na linguagem de programação C#, utilizando o Visual Studio 2017. Para resolução do método aproximativo foi utilizada a interface desenvolvida, em um computador DELL (2.50 GHz) processador core i7, com 8Gb de memória RAM, sob a plataforma Windows 10 home.

O modelo matemático empregado para solucionar o problema de planejamento florestal espacial foi o modelo I, proposto originalmente por Kidd et al. (1966), e assim denominado por Johnson e Scheurman (1977). Com o objetivo de maximizar o Valor Presente Líquido Global (VPL) da floresta, a função objetivo foi estabelecida assim:

$$\text{Max}Z = \sum_{i=1}^m \sum_{j=1}^n C_{ij} X_{ij} \quad (1)$$

S.t.

$$\sum_{i=1}^m \sum_{j=1}^n X_{ij} = 1 \forall i = (1 \dots m) \quad (2)$$

$$\sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij} \geq D \min \forall k = (0 \dots h-1) \quad (3)$$

$$\sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij} \leq D \max \forall k = (0 \dots h-1) \quad (4)$$

$$V_{H(k+1)} \geq (1 - \alpha) V_{H(k)} \forall k = (0 \dots h-1) \quad (5)$$

$$V_{H(k+1)} \leq (1 + \beta) V_{H(k)} \forall k = (0 \dots h-1) \quad (6)$$

$$\sum_{i=1}^m \sum_{j=1}^n A_{ijk} X_{ij} \geq \frac{A_t}{r} (1 - \lambda) \forall k = (1 \dots r) \quad (7)$$

$$\sum_{i=1}^m \sum_{j=1}^n A_{ijk} X_{ij} \leq \frac{A_t}{r} (1 + \lambda) \forall k = (1 \dots r) \quad (8)$$

$$n_i X_{ij} + \sum_{i \in N_i} X_{ij} \leq n_i \forall i, k. \quad (9)$$

$$X_{ij} \in \{0, 1\} \quad (10)$$

$$\text{sendo : } V_{HK} = \sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij}$$

em que:

Z= valor presente líquido global (R\$); X_{ij} = variáveis de decisão, representando o j-ésima prescrição de manejo adotada na i-ésima UM; C_{ij} = valor presente líquido de cada unidade de manejo i, gerenciada com a prescrição de manejo j; M = número total de unidades de manejo (UM); N= total de prescrições de manejo para o i-ésima UM; V_{ijk} = volume (m^3) produzido no período k, através de i-ésima UM adotando a j-ésima prescrição de manejo; $Dmin_k$ e $Dmax_k$ são as demandas mínimas e o máximas volumétricas (m^3), respectivamente, em cada período do horizonte de planejamento. n_i refere-se ao número de unidades de manejo adjacentes que apresentam cortes no período k.

De acordo com a função objetivo do modelo de programação linear inteira mista, (1), o objetivo é maximizar o valor presente global, sujeito as restrições de singularidade, (2,10), produções mínimas (3) e máximas (4) em cada período do horizonte de planejamento, controle sobre o fluxo de produção durante o horizonte de planejamento (5,6), e regulação da produção (7,8), que permite uma variação α para flexibilizar o atendimento dessa restrição. A restrição (9), assegura que nenhuma área adjacente será cortada no mesmo período k .

A GRASP é um processo multi-start ou iterativo, em que cada iteração GRASP consiste em duas fases: uma de construção, na qual uma solução viável é produzida, e uma de busca local, na qual a melhor solução na vizinhança da solução construída é procurado. A melhor solução global é mantida como resultado, (Figura 29). O principal parâmetro para Grasp é o α ($\alpha \in [0, 1]$), que expressa o compromisso entre a exploração de busca (intensificação usando mais ganância) e pesquisa de exploração (diversificação usando mais aleatoriedade). Pequenos valores para α permitem valores maiores para a qualidade média dos elementos da lista RCL e, incentiva a exploração. Quando $\alpha = 1$, o algoritmo é ganancioso determinista. Quando $\alpha = 0$, o algoritmo é ganancioso aleatório. (TALBI, 2009). A performance da meta-heurística é bastante sensível ao parâmetro α .

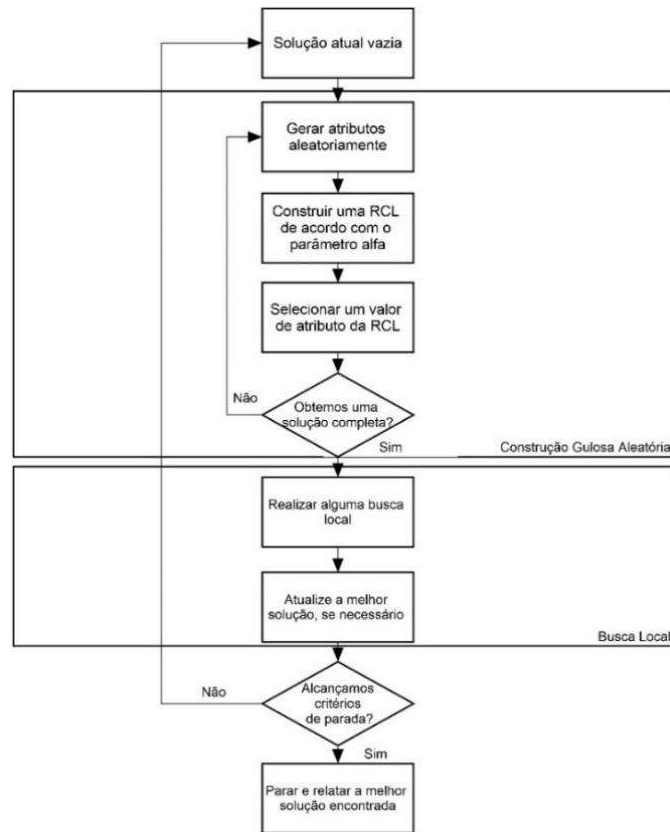


Figura 29 - Fluxograma do processo de busca do algoritmo GRASP. Adaptado de Yin e Wang (2012).

A representação da solução é feita utilizando um vetor de tamanho n , onde n corresponde ao número de unidades de manejo do problema. Para cada posição do vetor é assinalado uma prescrição j ($j = 1, 2 \dots M$). A função de avaliação utilizada no problema foi a de maximização do valor presente líquido global. As penalidades impostas referem-se a variação volumétrica acima ou abaixo da demanda estabelecida, áreas com cortes adjacentes no mesmo período, e regulação florestal ao final do horizonte de planejamento. Estas restrições foram definidas assim:

$$f(x) = \sum_{i=1}^m \sum_{j=1}^n C_{ij} X_{ij} - \alpha \left(D_k - \sum_{i=1}^m \sum_{j=1}^n V_{ijk} X_{ij} \right)^2 - \beta \left(\sum_{k=0}^{h-1} y_i \right)^2 - \gamma \left(R_1 - \sum_{i=1}^m A_i X_{ij} \right)^2$$

em que :

C_{ij} = Valor presente líquido associado a unidade de manejo i , manejada segundo a prescrição j ;

X_{ij} = são variáveis de decisão, representando a j -ésima prescrição de manejo adotada na i -ésima unidade de manejo;

V_{ijk} = e o volume (m³) produzido, no período k, pela i-ésima unidade de manejo adotando-se a j-ésima prescrição de manejo;

α , β , γ = coeficientes de penalidades associados a cada restrição.

D_k = demanda volumétrica no k-ésimo período do horizonte de planejamento

R_i = área regulatória

A_i = área da unidade de manejo i

y_i =somatório das áreas das unidades de manejo adjacentes cortadas no mesmo período

4 - Resultados e Discussão

As três alternativas avaliadas resultaram em boas soluções, com algumas penalidades não atendidas em alguns períodos do horizonte de planejamento, (Tabela 12).

Tabela 12 - Resumo dos resultados obtidos por método.

Método	Tempo de processamento	F.O	Volume total Colhido (m ³)	Penalidade de Regulação(ha)	Penalidade de Volume (m ³)	IAC
Exato	20min 02 seg	1.842.892,09	2.823.108,09	-	-	-
Grasp-1opt	02min e 51 seg	1.821.478,09	2.794.842,63	1,917	27.382,83	0,8998
Grasp-2opt	02min e 50 seg	1.762.879,02	2.817.736,75	0,000	6.728,65	0,922
Grasp/vns	04min e 35seg	1.846.990,99	2.811.652,34	0,000	5.819,40	1,004

O método exato demorou mais tempo para resolver o problema, o que já era esperado uma vez que este método realiza a busca em todo o espaço de soluções, a meta-heurística mais rápida foi a alternativa 2, e a mais lenta foi a alternativa 3, porém com menor soma de penalidades.

Na Tabela 13 estão as áreas para cada período após o período de transição, para a instância e idade regulatória de seis anos.

Tabela 13 - Resultados da área (ha) por período após horizonte de planejamento.

Periodo	Método exato	Grasp/1-opt	Grasp/2-opt	Grasp/VNS
1	377,08	361,10	382,05	374,65
2	362,29	349,38	337,70	373,97
3	334,51	369,67	300,17	340,19
4	286,22	298,34	340,10	285,98
5	274,47	263,23	276,42	255,17
6	257,51	250,36	255,64	262,12

Apenas a alternativa 1, resultou em uma penalidade de 1,91 ha, sendo o limite mínimo de 252,27 ha não atingido, as outras alternativas não apresentaram penalidades para esta restrição (Figura 30).

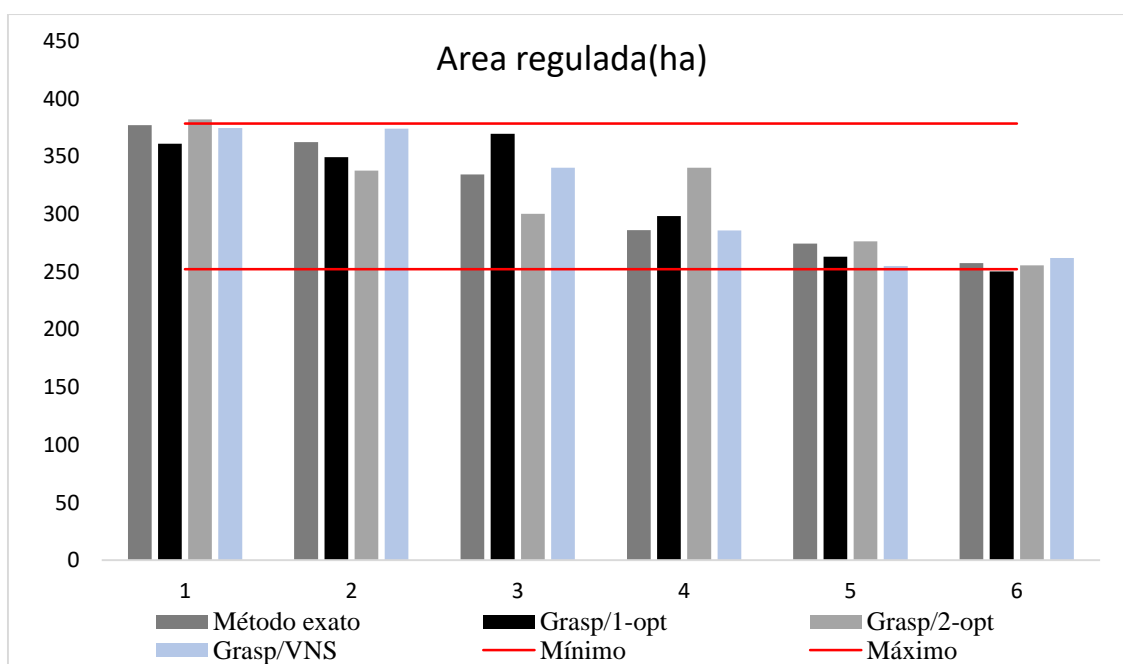


Figura 30 – Resultados da restrição de regulação por algoritmo avaliado.

Em relação a restrição volumétrica de demanda mínimas e máximas, a alternativa 1 resultou em uma penalidade apenas no período 16 do horizonte de planejamento, os demais anos foram todos atendidos (Tabela 14 e a Figura 31).

Tabela 14 – Volume total produzido (m³) em relação ao algoritmo avaliado.

Período	Algoritmo Avaliado			
	Grasp/1-opt	Grasp/2-opt	Grasp/Vns	Método Exato
0	152.984,40	152.953,27	146.516,84	149.147,95
1	128.043,98	121.761,60	135.623,36	134.248,52
2	151.005,59	147.894,68	152.198,09	146.578,76
3	172.146,32	165.820,66	156.507,67	158.585,74
4	153.429,89	160.331,92	164.747,90	179.149,46
5	149.234,83	162.081,66	172.847,50	161.235,52
6	149.610,13	140.020,36	147.154,78	137.505,53
7	131.758,92	133.040,61	122.531,88	132.807,78
8	118.166,03	121.682,27	120.141,87	122.196,16
9	126.158,11	126.250,26	120.237,39	127.473,33
10	121.843,46	145.956,72	121.567,89	126.455,64
11	140.993,14	131.890,03	143.072,80	136.571,10
12	140.611,88	162.073,72	158.035,99	148.005,31
13	169.853,63	149.910,16	146.591,05	140.636,00
14	137.094,36	145.353,19	130.780,83	146.434,66

15	154.657,09	159.912,69	147.715,10	147.364,94
16	183.186,39	142.035,56	169.281,37	169.173,42
17	163.195,68	168.705,81	180.650,43	179.359,07
18	150.868,81	180.061,60	175.449,59	180.179,21
Total(m³)	2.794.842,63	2.817.736,75	2.811.652,34	2.823.108,09

A produção total teve uma variação de -1% para a primeira alternativa, -0,19% e -0,40% para a segunda e terceira alternativas, em relação ao método exato, indicando bons resultados de maneira geral.

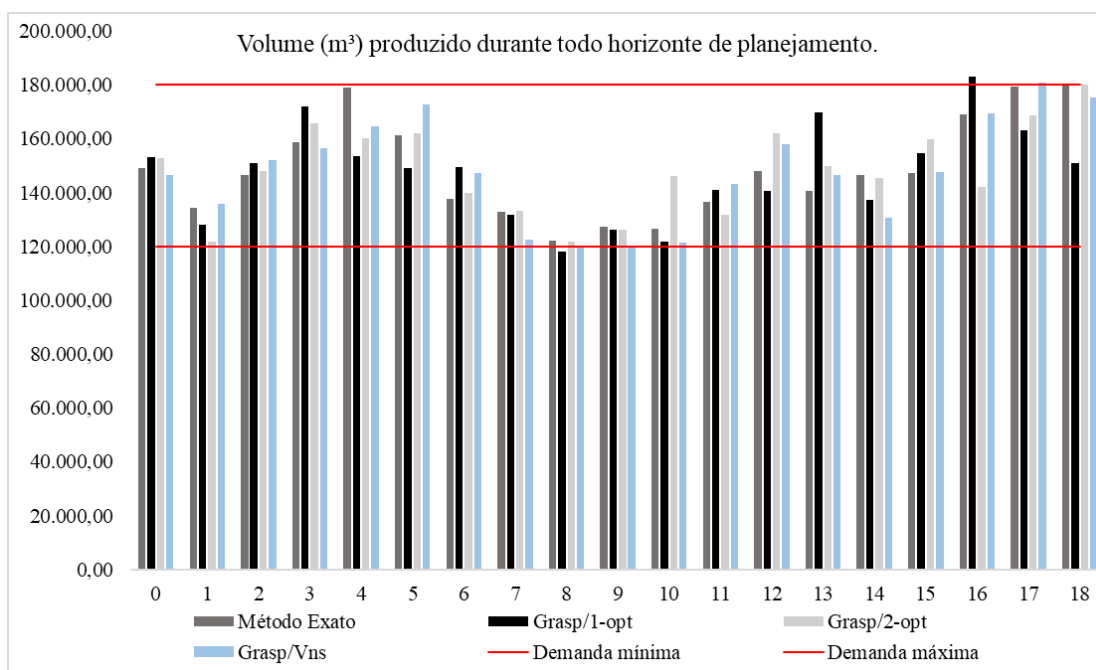


Figura 31- Volume produzido por cada método avaliado durante todo horizonte de planejamento.

Na Tabela 15 são apresentados os custos para cada alternativa avaliada. Em todas os custos de colheita foram menores que aqueles do método exato, porém, com menores volumes colhidos. O custo de implantação foi maior do que o custo com o método exato, para todas alternativas avaliadas.

Tabela 15 – Resumo dos custos das atividades de acordo com o algoritmo utilizado.

Custos (R\$)	Método exato	Grasp/1-opt	Grasp/2-opt	Grasp/VNS
Colheita (R\$)	45.835.358,69	45.516.575,70	45.676.907,86	45.705.858,46
Baldeio(R\$)	2.260.941,72	2.245.287,94	2.252.860,96	2.254.140,02
Transporte(R\$)	3.065.674,91	3.029.230,12	3.053.511,10	3.046.118,17
Silvicultura(R\$)	7.629.955,71	8.026.168,32	8.975.168,94	7.621.245,90
Implantação(R\$)	10.575.275,98	10.645.044,01	10.751.696,49	10.601.879,79

Custos Totais	69.367.207,02	69.462.306,09	70.710.145,35	69.229.242,33
Receita Total				
(R\$)	108.308.585,31	107.558.703,72	107.921.482,98	107.160.384,69

Barros et al. (2009) também avaliaram a meta-heurística GRASP para resolução de problemas de planejamento florestal estratégico, o valor do parâmetro alfa foi de 0,15 para a fase construtiva, avaliaram ainda a inclusão da técnica path relinking, esta técnica permite explorar caminhos conectando soluções elite, a inclusão da técnica foi fundamental para o bom desempenho da MH GRASP, obtendo resultados satisfatórios.

As Figuras (32, 33 e 34), encontram os planos de corte por período considerando a restrição de adjacência, para cada alternativa avaliada. Para a primeira alternativa o menor IAC ocorreu no 5 ano com um valor de 0,52, para a segunda alternativa o menor valor foi de 0,59 e ocorreu no 14 ano, e para a terceira alternativa foi de 0,51 no 1 ano.

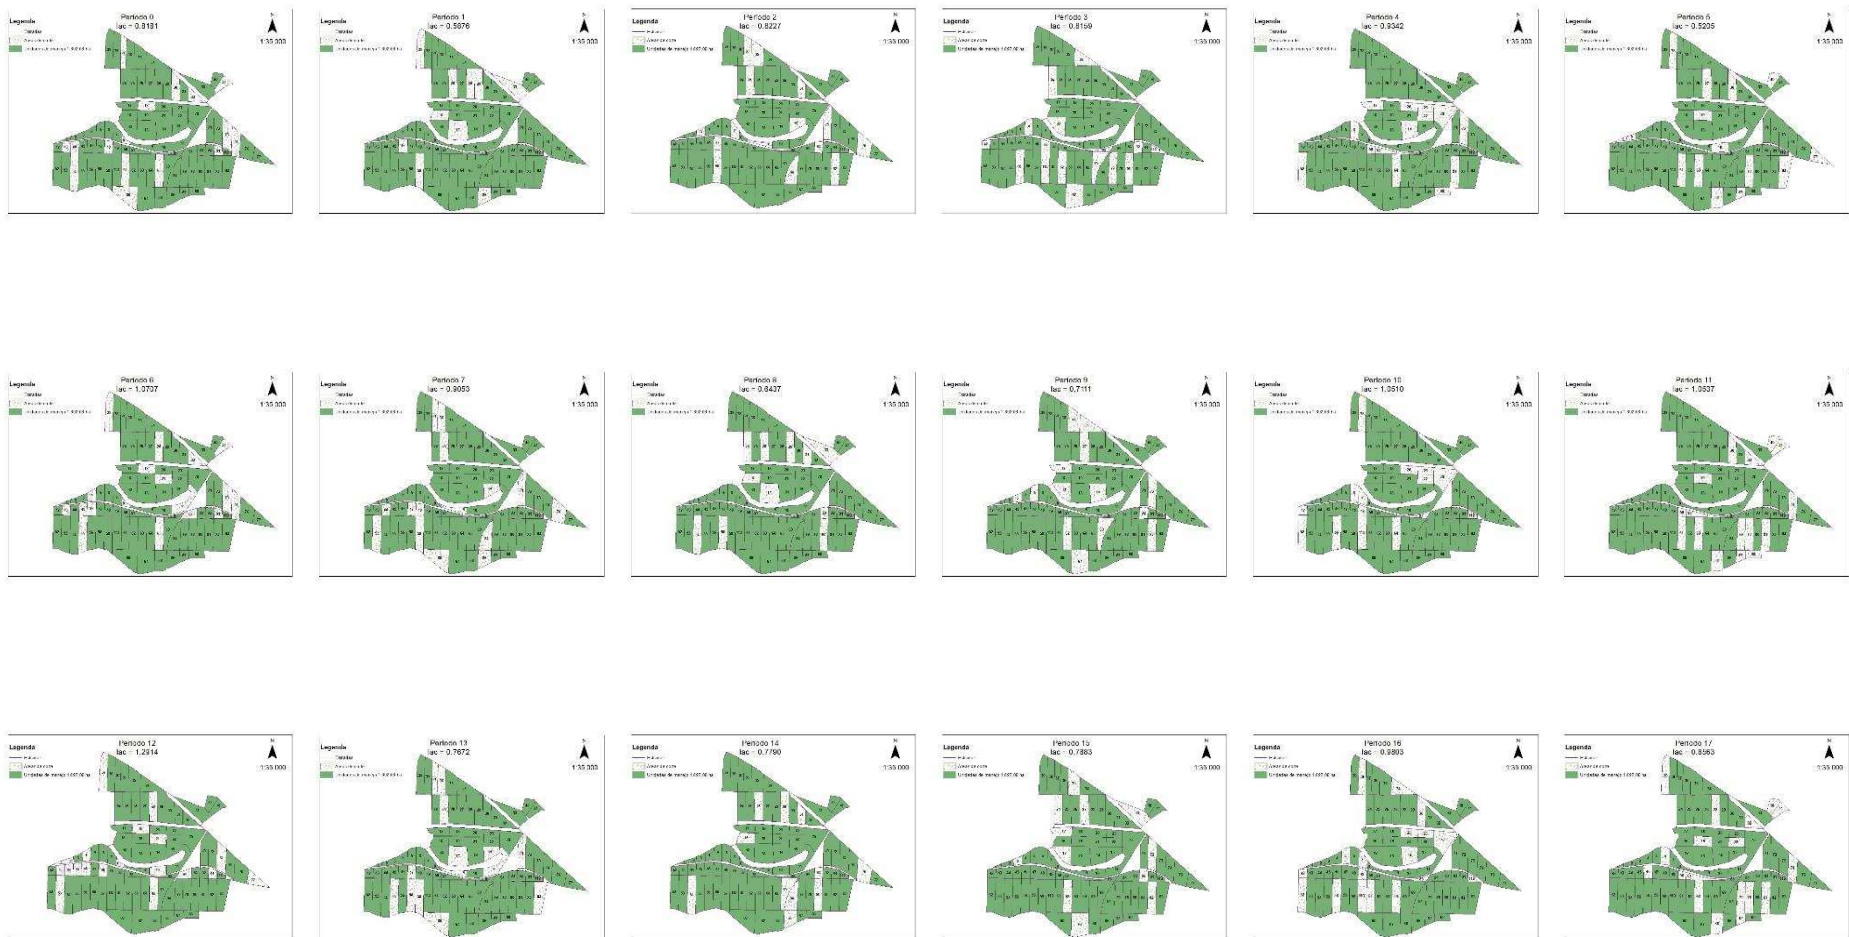


Figura 32 – Resultados do plano de corte por período utilizando a GRASP com a busca local de 1-opt.

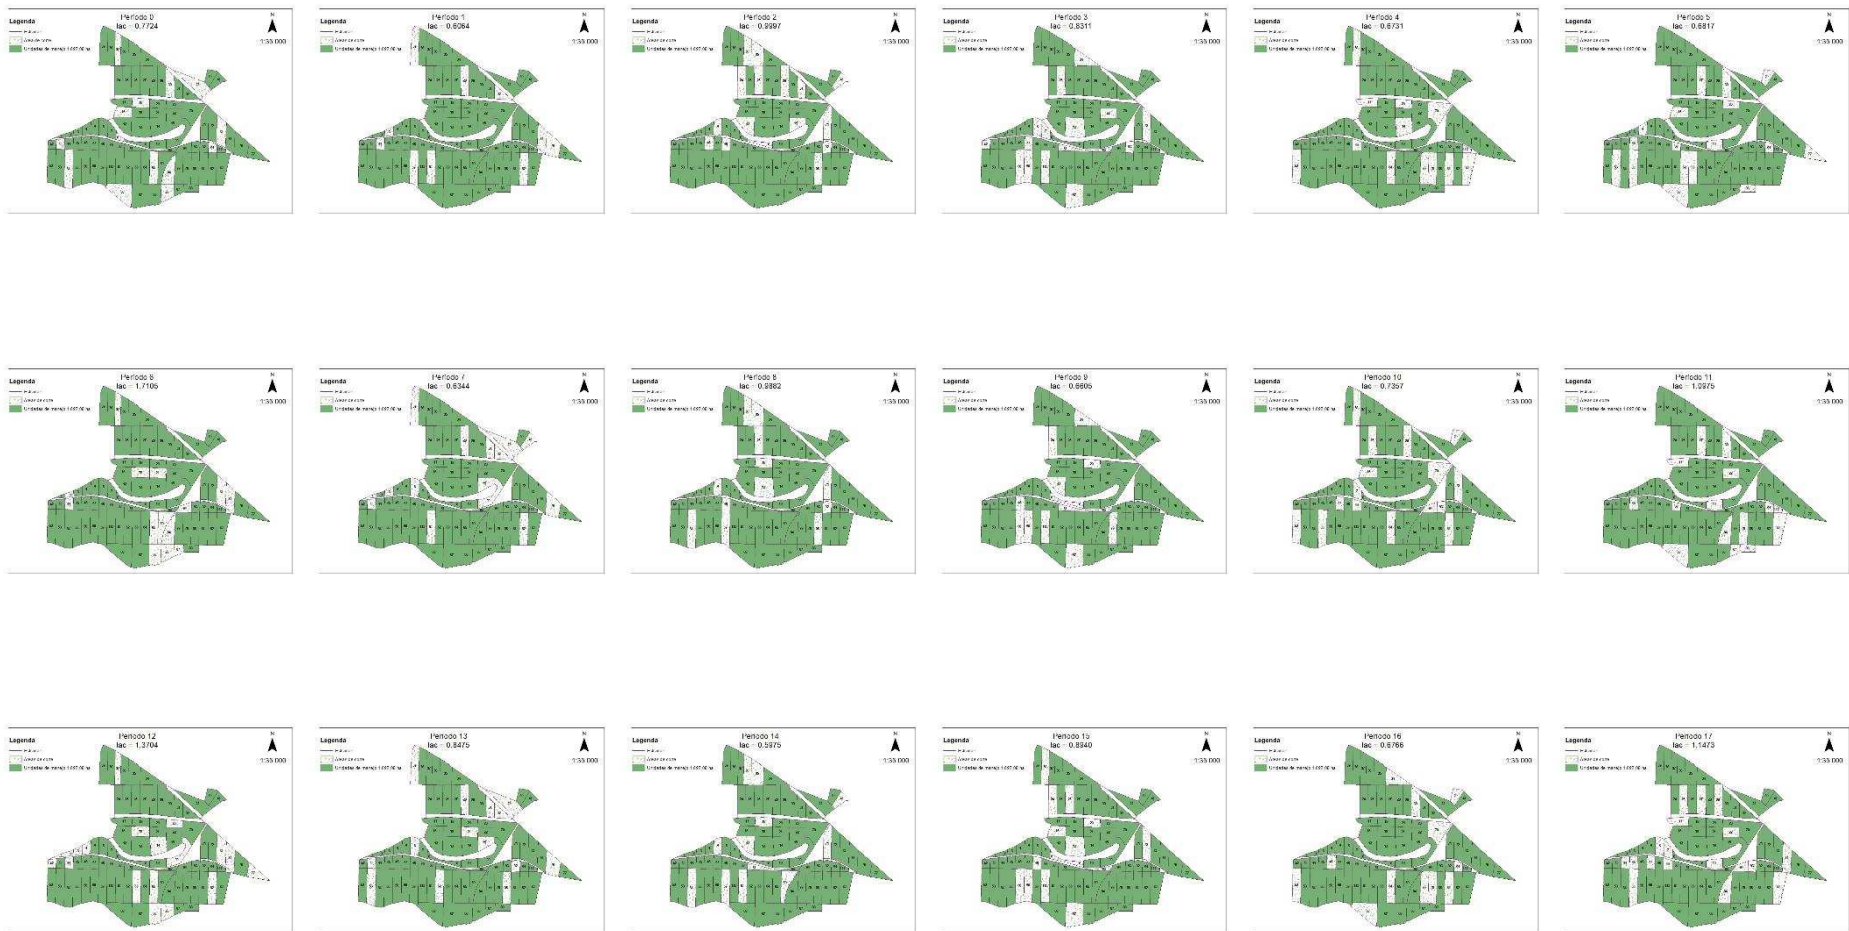


Figura 33 - Resultados do plano de corte por período utilizando a GRASP com a busca local de 2-opt.



Figura 34 - Resultados do plano de corte por período utilizando a GRASP com a busca local VNS.

5 - Conclusões

A meta-heurística GRASP foi eficiente para resolver a instância avaliada. O valor presente líquido global obtido variou de 95% a 98% quando comparado com o valor obtido pelo método exato. Em relação ao tempo, os métodos aproximativos foram mais eficientes em gerar uma resposta para o problema, mas não conseguiram atingir a solução ótima.

6 - Referências Bibliográficas

BARROS JUNIOR, A.A.; ARROYO, J.E.C.; SANTOS, H. N. GRASP com path relinking para um problema de planejamento florestal, **Anais do XLI SBPO - Simpósio Brasileiro de Pesquisa Operacional**. p. 1953-1964. 2009.

BARROS JUNIOR, A.A.; DA SILVA, G. F; PEREIRA, G.W.; MELO, R. Aplicações de heurísticas para a solução de um problema de planejamento florestal. In: XVI Congresso Latino-Iberoamericano de Investigación Operativa e do XLIV Simpósio Brasileiro de Pesquisa Operacional, 2012, Rio de Janeiro-RJ. **Anais do XVI Congresso Latino-Iberoamericano de Investigación Operativa e do XLIV Simpósio Brasileiro de Pesquisa Operacional**.p.2430-2441.2012.

BETTINGER, P.; BOSTON, K.; KIM, Y.H.; ZHU, J. Landscape-level optimization using tabu search and stand density-related forest management prescriptions. **European Journal of Operational Research**, v.176, n.2, p.1265-1282. 2007.

BINOTI, D.H.B.; DA SILVA BINOTI, M.L.M.; LEITE, H.G.; GLERIANI, J.M.; CAMPOS, J.C.C. Regulation of even-aged forest with adjacency constraints. **Forest policy and economics**, v.20, p.49-57. 2012.

BUONGIORNO, J.; GILLESS, J.K., 2003. **Decision methods for forest resource management**. Academic Press. 439p.

FEO, T. A.; RESENDE, M. G. C. A probabilistic heuristic for a computationally difficult set covering problem. **Operations Research Letters**, v.8, 1989. p.67–71

FEO, T.A.; RESENDE, M.G., Greedy randomized adaptive search procedures. **Journal of global optimization**, v.6, n.2, p.109-133. 1995.

FESTA, P.; RESENDE, M.G., An annotated bibliography of GRASP–Part I: Algorithms. **International Transactions in Operational Research**, v.16, n.1, p.1-24. 2009.

MARTELL, D.L.; GUNN, E.A.; WEINTRAUB, A., 1998. Forest management challenges for operational researchers. **European journal of operational research**, v.104, n.1, p.1-17.

MOURA A.V.; SCARAFICCI R.A. Hybrid heuristic strategies for planning and scheduling forest harvest and transportation activities. In 2008 **11th IEEE International Conference on Computational Science and Engineering** p. 447-454. IEEE. 2008.

TALBI, EL-GHAZALI. **Metaheuristics: from design to implementation**. John Wiley & Sons, 593p. 2009.

YIN, P.Y.; WANG, T.Y. A GRASP-VNS algorithm for optimal wind-turbine placement in wind farms. **Renewable energy**. v.48, p.489-498. 2012.

WEINTRAUB, A.; MURRAY, A.T., Review of combinatorial problems induced by spatial forest harvesting planning. **Discrete Applied Mathematics**, v.154, n.5, p.867-879. 2006.

Anexo I – Formulação do modelo matemático utilizando o AMPL do Cplex Studio 12.5.

```
//número de talhões i;
int n=...;

//quantidade de prescrições de manejo j;
int m=...;

//períodos de planejamento;
int q = ...;

//Período para restrição de regulação;
int r = ...;

//demanda máxima e mínima de produção no período k;
float Dmax = ...;
float Dmin = ...;
float AR = ...;
float alfa = ...;
float beta = ...;
float teta = ...;

//matriz com as áreas de cada prescrição para fazer a restrição de
regulação com a idade regulatória r;
float b[1..n][1..m][1..r] =...;

//Coeficientes de produção
float p[1..n][1..m] =...;

//Coeficientes de produção
float v[1..n][1..m][1..q] =...;

// Matriz de adjacência
int mao[1..n][1..n] =...;

// Matriz de prescrições
int presc[1..n][1..m][1..q] = ...;

// Quantidade de adjacentes
int nadj[1..n] = ...;

//variável de decisão Xij
//Corta (1) ou não (0) o talhão i no manejo j
dvar boolean x[1..n][1..m];

//variável de decisão Yik
//Corta (1) ou não (0) o talhão i no período k
dvar boolean y[1..n][1..q];

//Função objetiva maximizar o VPL
maximize sum(i in 1..n, j in 1..m) p[i][j]*x[i][j];

subject to {

//restrição de singularidade de cada talhão i só pode escolher uma
prescrição j.
forall(i in 1..n)
sum (j in 1..m) x[i][j] == 1;

//restrição de regulação para r
forall(k in 1..r)
```

```

sum(i in 1..n, j in 1..m) b[i][j][k]*x[i][j] >=(1-teta)*(AR/r);

forall(k in 1..r)
sum(i in 1..n, j in 1..m) b[i][j][k]*x[i][j] <= (1+teta)*(AR/r);

//Restrição de demanda de produção por período:
forall(k in 1..q-1)
sum(i in 1..n, j in 1..m) v[i][j][k] * x[i][j] >= Dmin;

forall(k in 1..q-1)
sum(i in 1..n, j in 1..m) v[i][j][k] * x[i][j] <= Dmax;

//Restrição de demanda de produção por período:
forall(k in 1..q-1)
sum(i in 1..n, j in 1..m)v[i][j][k+1]* x[i][j] >= (1-alfa)* sum(i in
1..n, j in 1..m)v[i][j][k]* x[i][j];

forall(k in 1..q-1)
sum(i in 1..n, j in 1..m)v[i][j][k+1]* x[i][j] <= (1+beta)* sum(i in
1..n, j in 1..m)v[i][j][k]* x[i][j];

// Restrição de adjacência de não cortar 2 talhões adjacentes no mesmo
período original
forall(i in 1..n)
forall(k in 1..q)
(sum(ii in 1..n) mao[ii][i] * y[ii][k]) + nadj[i] * y[i][k] <=
nadj[i];

forall(k in 1..q)
forall(i in 1..n)

y[i][k] >= sum(j in 1..m) presc[i][j][k] * x[i][j];

}

execute{
  writeln("Valor ótimo= ", cplex.getObjValue());
  writeln("X(i,j,)"
    for(var i = 1 ; i <= n ; i++)
      for(var j = 1 ; j <= m; j++)
        for(var k = 1 ; k <= q; k++)
          if(x[i][j] > 0){
            writeln("X", i, j, " = ",
x[i][j]);
          }
}
}

```

Conclusões Gerais

A interface desenvolvida resolveu o problema do planejamento florestal estratégico com restrições de adjacência proposto com eficiência e pode ser utilizado para resolução de problemas similares.

A MH GRASP apresentou os melhores resultados em relação as meta-heurísticas avaliadas.

No geral as MH atenderam as restrições de demanda e de regulação, sendo a restrição de adjacência a que mais dificulta a resolução do problema de planejamento florestal estratégico.