

TRABALHO DE CONCLUSÃO DE CURSO

ENGENHARIA FLORESTAL

**UTILIZAÇÃO DA METAHEURÍSTICA ALGORITMO
GENÉTICO EM UM MODELO DE REGULAÇÃO DA
PRODUÇÃO FLORESTAL**

LISANDRA MARIA ALVES MATOS



Lisandra Maria Alves Matos

**UTILIZAÇÃO DA METAHEURÍSTICA ALGORITMO GENÉTICO EM UM MODELO
DE REGULAÇÃO DA PRODUÇÃO FLORESTAL**

Trabalho de conclusão de curso apresentado ao
Instituto de Ciências Agrárias da Universidade Federal
de Minas Gerais, como requisito parcial, para a
obtenção do título de Bacharel em Engenharia Florestal

Orientador: Prof. Dr. Carlos Alberto Araújo Júnior


Montes Claros
2017

Lisandra Maria Alves Matos. UTILIZAÇÃO DA METAHEURÍSTICA ALGORITMO GENÉTICO EM UM MODELO DE REGULAÇÃO DA PRODUÇÃO FLORESTAL.

Aprovada pela banca examinadora constituída por:

Prof. Dr. Christian Dias Cabacinha – ICA/UFMG

Prof. Dra. Adriana Leandra de Assis – ICA/UFMG



Prof. Dr. Carlos Alberto Araújo Júnior – Orientador ICA/UFMG

Montes Claros, 23 de novembro de 2017.

À minha mãe que nunca deixou de me incentivar a seguir meu coração e lutar pelo que me faz feliz. Essa é para senhora.

AGRADECIMENTOS

Ao meu Deus por ouvir minhas orações quando clamava por consolo, por cuidar de mim e sempre estar ao meu lado. Sempre Te pedi para colocar Seus sonhos no meu coração e espero estar trilhando o caminho que escolheu para mim.

Obrigada à minha mãe que, juntamente com meus irmãos, Larissa, Filipe e Gabriel, foi minha válvula de escape. Obrigada por aceitar minhas escolhas e me dar todo o suporte. Ao meu pai, porque sei que o tempo em que esteve conosco só desejou o melhor para todos nós. Obrigada a minha vó Piedade e aos meus tios e primos por compreenderem os períodos de ausência. Obrigada também a família de São Paulo que mesmo de longe me incentivou e me apoiou incondicionalmente. Amo todos vocês.

Obrigada Leonardo por acreditar em mim quando muitas das vezes nem eu acreditava. Sua garra e paixão pela profissão que escolhemos seguir me inspiram e espero poder inspirar pessoas como você faz. E obrigada pela cafeteira que talvez tenha sido um dos fatores que possibilitou a conclusão desse trabalho.

Obrigada ao Fantastic Four, Marcony, Daisy e Gabriel, que de mansinho conquistou meu coração e me fazia descarregar um pouco da tensão durante nossos cafezinhos. Obrigada ao Brutus 301, Amanda, Letícia, Naiara e Adelaide, e ao 202 do poder, Ângela, Márcia, Alécia, Sabrina, Poliana e Jussara, os melhores lares que eu poderia ter encontrado em Montes Claros. Obrigada pelo companheirismo de sempre.

Aos meus antigos colegas de turma, obrigada pelo convívio, por terem estado comigo desde o início, principalmente Kelly, que estava ao meu lado não importando minhas mudanças de humor, e ao Alisson por me emprestar a família dele e fazer eu me sentir em casa.

Obrigada ao meu orientador, Carlos, que me ensinou que pensar é a maior dádiva do ser humano e que não deve ser desperdiçada com ideias prontas. Obrigada por aguentar minhas crises e ser meu psicólogo mesmo quando não percebia ou não pretendia ser. Em você encontrei um amigo e espero manter essa amizade enquanto colegas de profissão. Obrigada por ser o melhor orientador ever.

Ao demais professores da área de manejo florestal, Adriana e Christian, e ao corpo docente do curso de engenharia florestal por depositarem confiança em mim sempre que foi preciso.

Enfim, manifesto aqui toda a minha gratidão a todos que tornaram possível a realização desse trabalho.

“Adquire a sabedoria, adquiere inteligência e não te esqueças nem te apartes das palavras da minha boca. Não a abandones e ela te guardará, ama-a e ela te protegerá”.

(Provérbios 4. 4-5)

RESUMO

O desenvolvimento de técnicas e ferramentas que auxiliem no gerenciamento de florestas é uma das diretrizes do manejo florestal. Nesse sentido, em termos de planejamento das atividades florestais, um dos quesitos mais importantes é a definição do modelo de regulação considerado e a indicação das ferramentas de programação matemática mais apropriada para solucioná-lo. Mais recentemente, técnicas de inteligência artificial, principalmente as metaheurísticas, têm sido utilizadas para tal finalidade, a exemplo dos algoritmos genéticos (AG), os quais tem na escolha dos parâmetros sua maior dificuldade de aplicação pelos manejadores. Nesse contexto, o objetivo deste trabalho foi identificar a melhor parametrização para metaheurística algoritmo genético por meio de combinações de seus parâmetros para solução de problemas do planejamento florestal. O estudo foi desenvolvido considerando um horizonte de planejamento de 16 anos, analisando-se como parâmetros da metaheurística a utilização de elitismo, o tipo de cruzamento (1 ponto de corte e uniforme), o tipo de seleção dos pais para cruzamento (roleta e torneio) e tipo de mutação (escolha aleatória do gene e gene a gene), totalizando 16 combinações. Adicionalmente foram avaliados o tamanho da população inicial (20, 50 e 80 indivíduos) e o critério de parada (100, 300 e 500 gerações), totalizando 9 combinações. Cada uma dessas combinações de parâmetros do algoritmo genético foi considerada como um tratamento diferente e processado com 30 repetições. O problema objetivou encontrar um cenário de planejamento da produção florestal que retornasse o máximo Valor Presente Líquido (VPL) sujeita às restrições de idade de corte (entre 5 e 7 anos), de demandas mínima e máxima anual (140.000 m³ e 160.000 m³, respectivamente) e de integridade, onde apenas uma alternativa de manejo poderia ser adotada por unidade de manejo. O processamento foi efetuado utilizando-se o software MeP (*Metaheuristic for Forest Planning*) em desenvolvimento pelo Laboratório de Pesquisa Operacional e Modelagem Florestal (LPM) da Universidade Federal de Minas Gerais. Para comparar os resultados, optou-se pela aplicação do teste não-paramétrico de Kruskal-Wallis. Os resultados mostram que há diferença estatisticamente significativa, a 5% de probabilidade, entre as combinações dos parâmetros. Conclui-se que a qualidade das soluções geradas pela metaheurística algoritmo genético é dependente da seleção de uma boa configuração de seus parâmetros. A melhor solução foi encontrada utilizando a seguinte configuração: elitismo, cruzamento de 1 ponto, seleção do tipo torneio, mutação do tipo gene a gene, população inicial com 50 indivíduos e critério de parada com 500 gerações.

Palavras-chave: Inteligência artificial. Planejamento florestal. Manejo e gerenciamento de florestas. Programação matemática. Parametrização.

LISTA DE ILUSTRAÇÕES

Figura 1 - Funções do administrador no processo administrativo.....	13
Figura 2 - Saída de produtos madeireiros ao longo do tempo dentro de limites pré-definidos.....	16
Figura 3 - Saída de produtos madeireiros ao longo do tempo dentro de limites pré-definidos.....	18
Figura 4 - Interface entre as áreas de IC, IA e PO.....	22
Figura 5 - Estrutura geral do algoritmo genético	23
Figura 6 - Crossover de um ponto gerando novos indivíduos.....	26
Figura 7 - Exemplo de funcionamento do operador genético de mutação	27
Figura 8 - Distribuição de área de plantio por classe de idade.....	28
Figura 9 - Layout do MeP	31
Figura 10 – Volumes obtidos pela combinação 13 (a) e pela combinação 4 (b) distribuídos ao longo dos 16 anos do horizonte de planejamento.....	34
Figura 11 - Estrutura da evolução das buscas pelos valores médios de fitness obtidos pelo AG nas 16 combinações testadas ao longo de 100 gerações.....	34

LISTA DE TABELAS

Tabela 1 - Custos empregados para cálculo do VPL de cada solução obtida pelo AG.....	28
Tabela 2 - Valores máximo, médio, mínimo, desvio padrão e eficácia dos fitness gerados pelas combinações entre os parâmetros do algoritmo genético.....	33
Tabela 3 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis fitness para as 16 combinações dos parâmetros.	37
Tabela 4 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis fitness para os 2 operadores de seleção testados.	38
Tabela 5 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis fitness para os 2 tipos de cruzamento testados.	38
Tabela 6- Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis fitness para os 2 tipos de cruzamento testados.	39
Tabela 7 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis fitness para os 2 tipos de cruzamento testados.	40
Tabela 8 - Valores máximo, médio, mínimo, desvio padrão e eficácia dos fitness gerados e tempo de processamento das combinações entre tamanho da população inicial e número de gerações.	40
Tabela 9 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado às combinações entre tamanho de população inicial e número de gerações.....	41
Tabela 10 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis fitness para os diferentes tamanhos de população testados.	41
Tabela 11 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis fitness para os diferentes tamanhos de população testados.	42
Quadro 1 - Combinações dos parâmetros do algoritmo genético testadas	30

LISTA DE ABREVIATURAS E SIGLAS

AG	- Algoritmo Genético
BT	- Busca Tabu
IA	- Inteligência Artificial
IC	- Inteligência Computacional
LPM	- Laboratório de Pesquisa Operacional e Modelagem Florestal
MeP	- <i>Metaheuristic for forest Planning</i>
PO	- Pesquisa Operacional
PI	- Programação Inteira
PL	- Programação Linear
PLI	- Programação Linear Inteira
SA	- <i>Simulated Annealing</i>
VPL	- Valor Presente Líquido

SUMÁRIO

1 INTRODUÇÃO	11
2 REFERENCIAL TEÓRICO	13
2.1 Planejamento Florestal	13
2.2 Regulação da Produção Florestal	16
2.3 Programação Matemática	18
2.3.1 Programação Linear.....	19
2.3.2 Programação Linear Inteira	20
2.4 Meta-heurística Algoritmo Genético	21
2.4.1 Parâmetros do Algoritmo Genético	23
2.4.1.1 Função objetivo	24
2.4.1.2 População inicial	24
2.4.1.3 Operadores de seleção	24
2.4.1.3.1 Método da roleta.....	24
2.4.1.3.2 Método por torneio	25
2.4.1.4 Operadores genéticos.....	25
2.4.1.4.1 Operador crossover.....	25
2.4.1.4.2 Operador de mutação.....	26
2.4.1.5 Elitismo.....	27
3 MATERIAL E MÉTODOS	28
3.1 Base de Dados	28
3.2 Descrição do Problema de Planejamento Florestal	28
3.3 Algoritmo Genético	30
3.4 Processamento	31
3.5 Análise dos resultados	32
4 RESULTADOS E DISCUSSÃO	33
5 CONCLUSÃO.....	43
REFERÊNCIAS	44

1 INTRODUÇÃO

O manejo florestal está associado à utilização de forma sustentável e sensata dos recursos florestais, de maneira que as gerações futuras possam usufruir ao menos dos mesmos benefícios da geração presente (SCOLFORO, 1998). Nesse contexto, é necessário que os gestores florestais conheçam as técnicas de planejamento e reconheçam sua importância para o sucesso do empreendimento. É por meio do planejamento que é possível organizar, racionalizar e otimizar as operações, tornando possível abordar todos os fatores que podem atingir positivamente ou negativamente as atividades, identificando e antecipando alguns problemas que viriam a afetá-las. Em geral, o planejamento é feito seguindo uma estrutura hierárquica, sendo dividido em estratégico (longo prazo), tático (médio prazo) e operacional (curto prazo).

O processo de produção florestal é caracterizado pelo longo prazo, principalmente pelo período de maturação da matéria-prima trabalhada, e isso é uma das dificuldades que tornam ainda mais complexos os problemas de planejamento florestal, introduzindo um maior grau de incerteza na previsão dos fatores envolvidos e consequente instabilidade (ARCE, 1997). Esse fato gera insatisfação nas empresas florestais quanto à correlação entre as ações planejadas e as executadas, principalmente quando a questão é sequenciamento de atividades.

A longo prazo, um dos quesitos mais importantes no planejamento florestal é a definição do modelo de regulação considerado e a indicação das ferramentas de programação matemática mais apropriada para solucioná-lo. O conceito de floresta regulada está ligado à sustentabilidade, com a viabilização da continuidade do processo e dos usos associados aos produtos madeireiros ou não-madeireiros. A conversão da floresta não regulada para uma situação que o seja, é a chamada regulação florestal. Pode-se dizer, então, que o principal objetivo da regulação florestal seja a definição e aplicação de prescrições de manejo de modo que se tenha o suprimento constante e contínuo da demanda de bens e serviços dentro dos limites da capacidade produtiva de cada área (DAVIS, 1966; CARVALHO, 2015; MAGALHÃES, 2015).

A complexidade em conjunto à quantidade de variáveis envolvidas nos modelos de regulação, incentivaram a introdução de diversas ferramentas da pesquisa operacional na área florestal, possibilitando a redução de riscos e incerteza na tomada de decisão (RODRIGUES, 2001). Dentre as técnicas aplicadas no manejo florestal estão a Programação Linear (PL) e a Programação Linear Inteira (PLI) (BETTINGER *et al.*, 2009). Apesar da grande aplicação da PL em casos de ordenamento e otimização da produção florestal (CASTRO, 2007), a necessidade de incorporação da restrição de integridade nos modelos de

regulação florestal tem levado à limitação do uso da técnica. Dessa forma, modelo de programação inteira (PLI) utilizando algoritmos exatos (*branch and bound*) e metaheurísticas (algoritmo genético, busca tabu, *simulated annealing*) têm sido aplicados na resolução de problemas de gerenciamento de recursos florestais (BETTINGER *et al.*, 2009).

A metaheurística algoritmo genético (AG) é uma ferramenta de busca e otimização que se baseia nos princípios Darwinianos de seleção natural e reprodução genética, utilizando princípios de sobrevivência e reprodução dos indivíduos mais aptos para produzir melhores soluções a cada geração (HILLIER & LIEBERMAN, 2006). O AG se enquadra nos métodos heurísticos por se basear em um procedimento que provavelmente vai encontrar uma excelente solução viável, mas não necessariamente uma solução ótima para o problema em questão. Porém, a geração de uma solução para um problema complexo mais rapidamente, por estar ligada a um bom desempenho e performance computacional, é uma importante razão pela qual a metaheurística é selecionada como uma ferramenta de planejamento, mesmo não garantindo a otimalidade da resposta (BETTINGER *et al.*, 2009).

A maior dificuldade em se utilizar esse algoritmo gira em torno do ajuste de seus parâmetros (GOMIDE, 2009). Por isso, é necessário que haja o desenvolvimento de pesquisas que forneçam subsídio para escolha das melhores configurações para os algoritmos de otimização que vêm sendo utilizados no planejamento florestal. Nesse contexto, o principal objetivo do presente trabalho foi identificar a melhor parametrização para a metaheurística algoritmo genético por meio de combinações de seus parâmetros para solução de problemas do planejamento florestal.


2 REFERENCIAL TEÓRICO

2.1 Planejamento Florestal

Administrar um empreendimento é uma atividade complexa, visto a quantidade de variáveis que devem ser analisadas. Dessa forma, a administração é praticada de forma a aprimorar os meios e desenvolver habilidades e competências gerais e específicas para atingir os resultados desejados em um empreendimento.

Chiavenato (2003) retrata o processo administrativo considerando quatro fases distintas: (1) planejar, (2) organizar, (3) direcionar e (4) controlar. O autor ainda ressalta que a abordagem dessas funções deve ser feita de forma cíclica, dinâmica e interativa (FIGURA 1).

Figura 1 - Funções do administrador no processo administrativo



Fonte: Adaptado de Chiavenato (2003).

O planejamento é a primeira das funções do processo administrativo e permite a existência das demais atividades do negócio. Isso possibilita a avaliação das melhores maneiras de se tomar determinada ação, de modo a alcançar os resultados esperados. Chiavenato (2003) menciona que planejar é determinar antecipadamente quais são os objetivos a serem atingidos detalhando os planos necessários para alcançá-los da melhor forma possível. De forma semelhante, Oliveira (2009) afirma que o planejamento é um processo desenvolvido para o alcance de uma situação futura desejada, de uma maneira mais eficiente, eficaz e efetiva, com a melhor concentração de esforços e recursos pela empresa.

Dessa forma, entende-se que o ato de planejar é o alicerce do processo administrativo, sendo crucial para o sucesso do empreendimento e, portanto, deve ser

desenvolvido de forma clara e estruturada. Nesse sentido, Chiavenato (2003) estabelece alguns aspectos básicos para se ter um adequado planejamento, a saber:

1. Estabelecimento de objetivos: a fixação de objetivos é o ponto de partida do planejamento. Os objetivos são os resultados futuros que se anseia atingir dentro de um certo espaço de tempo, aplicando os recursos disponíveis ou possíveis.
2. Desdobramento dos objetivos: decorrência da hierarquia dos objetivos das organizações, os quais vão desde os objetivos globais, que são amplos e genéricos, até os objetivos operacionais, que são mais restritos e detalhados. Assim, são desdobrados em: políticas, diretrizes, metas, programas, procedimentos, métodos e normas.
3. Abrangência do planejamento: há três níveis hierárquicos de planejamento, sendo eles o planejamento estratégico (mais amplo e abrange toda a organização, sendo projetado a longo prazo), tático (abrange cada departamento e é projetado para o médio prazo) e operacional (abrange cada tarefa ou atividade específica, sendo projetado para o curto prazo).
4. Tipos de planos: o plano é o resultado imediato do planejamento e descreve uma sequência de ações para se alcançar um objetivo. Os planos possuem em comum a previsão, a programação e a coordenação de um curso lógico de atividades, devendo orientar a busca dos objetivos determinados. Os planos podem ser separados em procedimentos (relacionados à métodos), orçamentos (relacionados com dinheiro), programas ou programações (relacionados com o tempo) e normas ou regulamentos (relacionados com comportamento).

Dessa maneira, o planejamento permite que a organização atue de forma a facilitar o desenvolvimento e a sustentabilidade do negócio com um maior grau de assertividade. Essa é a essência do planejamento em todas as áreas do mercado, apesar das particularidades de cada uma delas, a exemplo do setor florestal. Nesse caso, a mais acentuada delas é o horizonte de atuação que envolve o longo prazo, principalmente por dois motivos: a matéria prima trabalhada leva um período maior para atingir a maturação ideal e as questões econômicas e de mercado, as quais podem provocar alterações significativas nas estratégias adotadas nas empresas florestais (RODRIGUES, 2001). Arce (1997) cita o longo prazo, característico do processo de produção florestal, como uma das dificuldades que tornam particularmente complexas as decisões do planejamento florestal, o que acaba introduzindo um maior grau de incerteza sobre as condições econômicas e biológicas futuras.

Apesar disso, o planejamento de um empreendimento florestal segue a premissa de tomar decisões de forma a alcançar melhores resultados no futuro, identificando as oportunidades, ameaças, forças e até mesmo fraquezas que possam afetar o negócio. Bettinger *et al.* (2009) conceituam planejamento florestal como o processo de descrição específica de eventos que devem ser realizados para alcance dos objetivos estabelecidos pelo empreendedor. Corroborando isso, Schneider (2009) afirma que é a partir de um planejamento bem estruturado que são traçados os pontos de atenção e as estratégias para execução das atividades necessárias para se alcançar os objetivos desejados em um determinado período de tempo.

Assim, conhecer bem o conceito de planejamento florestal é importante para que as atividades sejam implementadas de forma correta, a previsão de cortes futuros seja realizada, o uso de recursos naturais limitados seja otimizado e haja a manutenção e/ou criação de áreas de conservação (BETTINGER *et al.*, 2009). É o planejamento que responde perguntas sobre o que fazer, quando, quanto, como, onde, para quem, por que e por quem. Sua importância ainda envolve a dificuldade ou até mesmo a irreversibilidade de consequências indesejadas quando o plano é feito de forma inadequada ou quando as decisões são embasadas em planos cujo horizonte de planejamento tem um curto prazo (AUGUSTYNCZIK, 2014).

Para definir o tamanho do horizonte de planejamento é necessário identificar o período de tempo em que se aceita correr riscos em se fazer pressuposições para as atividades que serão realizadas. Para o caso florestal, esse período está ligado ao tempo de obtenção do produto e à exaustão dos recursos investidos. Deve-se considerar, ainda, que quanto maior o horizonte de planejamento, maiores são as chances de distanciamento das metas por diversos fatores, tais como mudança no cenário econômico, custos acima do projeto e surgimentos de novas tecnologia. Por outro lado, se o período for muito curto corre-se o risco de não se considerar eventos importantes para o retorno do negócio (CAMPOS; LEITE, 2013).

Tais considerações influenciam a adequada tomada de decisão quanto à abrangência que o plano pode assumir, sendo, portanto, necessário que se compreenda os diferentes níveis de planejamento. Hierarquicamente, o planejamento para a gestão dos recursos florestais pode ser feito a longo, médio e curto prazo. Um planejamento de longo prazo dura em média dezoito a vinte e dois anos, o de médio prazo varia entre quatro e sete anos e o planejamento de curto prazo varia entre doze e dezoito meses (NOLASCO, 2012). Essa classificação do planejamento quanto ao horizonte também pode ser encontrada na literatura como: estratégico (longo prazo), tático (médio prazo) e operacional (curto prazo).


O planejamento estratégico ou de longo prazo considera várias premissas para a formulação dos objetivos e dos planos de ação para sua execução, de maneira a garantir a sustentabilidade no fornecimento da matéria-prima para o processo. O plano de longo prazo deve ser otimizado, afim de definir o melhor manejo para a base florestal atual e futura e de ser o norteador para dos demais planos de abastecimento de médio e curto prazo (BINOTI, 2010; WERNEBURG, 2015).

2.2 Regulação da Produção Florestal

Dentro do plano estratégico, um dos maiores desafios do planejamento florestal é a chamada regulação florestal. A essência de se ter uma floresta regulada estabelece que as classes de idade e tamanho das árvores sejam representadas em uma tal proporção e estejam crescendo de forma consistente a taxas que induzam a uma produção aproximadamente igual ou periódica de produtos de qualidade e tamanho desejáveis (DAVIS, 1966). Dessa forma, uma progressão de classes de tamanho e idade deve existir para que as unidades de manejo passíveis de corte e com volume aproximadamente iguais, estejam regularmente disponíveis para a exploração (FIGURA 2). Esse conceito se torna importante a partir da premissa de que as empresas devem atender a uma demanda pré-estabelecida de produtos florestais, mesmo possuindo unidades de manejo com diferentes idades e tamanhos, localizadas em diferentes capacidades produtivas.

Nessas condições, os empreendedores têm dificuldades em prever alterações futuras e manter o fluxo constante sem impactos no fornecimento dos produtos florestais. É nesse contexto que o conceito de regulação florestal é ligado à ideia de produção sustentável, que é o atendimento contínuo da demanda por bens e serviços dentro dos limites da capacidade produtiva, sem comprometer a aptidão da área (DAVIS, 1966). Da mesma forma, Carvalho (2015) e Magalhães (2014) afirmam que a regulação florestal está ligada a sustentabilidade das florestas, com a viabilização da continuidade da produção dos produtos e usos da floresta.

Figura 2 - Saída de produtos madeireiros ao longo do tempo dentro de limites pré-definidos



Fonte: Adaptado de Bettinger *et al.* (2009).

A partir de uma floresta regulada é possível obter, dentre outros aspectos: (a) produções aproximadamente iguais por ano em relação à volume, tamanho, qualidade e valor da madeira, possibilitando uma base sólida para o planejamento do empreendimento como um todo; (b) o volume colhido no ano e a receita não serão maiores do que o necessário, já que são obtidos do estoque de crescimento; (c) estabilidade no balanço entre receitas e custos anuais; (d) maior proteção florestal por permitir maior controle com a estrutura balanceada de idade; (e) uso regular e contínuo da mão-de-obra disponível (DAVIS, 1966).

Embora seja de crucial importância, converter uma floresta não regulada para uma que o seja é uma das maiores dificuldades do manejo florestal. Isso acontece principalmente pelos acréscimos ou redução na área de plantio ao longo do horizonte de planejamento, pelos avanços tecnológicos e pelas alterações na demanda anual de produtos florestais (CASTRO, 2007). Outro fator limitante é a complexidade que o problema pode assumir, uma vez que envolve um grande número de variáveis envolvidas no processo. Essa complexidade torna difícil sua resolução utilizando-se técnicas manuais, o que pode tornar inviável sua utilização sem o auxílio de ferramentas de programação matemática.

Com o avanço da pesquisa científica, modelos de programação linear para regulação florestal foram desenvolvidos e posteriormente agrupados por Johnson e Scheurman (1977) em duas classes, denominadas de modelo tipo I e modelo tipo II. O primeiro possibilita uma subdivisão da floresta em unidades de manejo homogêneas, segundo critérios estabelecidos anteriormente pelo modelador. Em seguida, é prescrito um conjunto de alternativas de manejo pré-determinado para cada uma das unidades, que representam sequências de ações que ocorrerão ao longo do horizonte de planejamento, como por exemplo a idade de colheita de uma determinada área. Dessa forma, após a definição de determinada prescrição, a unidade de manejo seguirá sobre tal processo ao longo de todo o horizonte de planejamento, o que possibilita manter a sua identidade física. Em contrapartida, o modelo tipo II permite que áreas cortadas em um determinado período sejam recombinadas em novas unidades de manejo, que são agrupadas pela sua idade, mas não necessariamente são adjacentes. É essa flexibilidade do modelo que leva a perda da identidade física das unidades de manejo, permitindo uma maior maleabilidade na identificação de novas unidades (RODRIGUES, 2001).

A principal vantagem de se formular problemas florestais pela metodologia do modelo tipo II está no menor número de variáveis de decisão quando comparado com o modelo tipo I, o que, conseqüentemente, exige menor esforço computacional durante o processamento dos dados. Porém, no momento da formulação das alternativas de manejo, as

características do modelo tipo II podem implicar em modificações drásticas quando usada a programação inteira, que, juntamente com a programação linear, vem sendo utilizada com frequência em modelos de regulação florestal (RODRIGUES *et al.*, 2006).


A maior utilização da programação matemática se deve ao avanço da tecnologia computacional aliada à matemática, possibilitando a inclusão de muitas variáveis na resolução de problemas florestais que antes não poderiam ser resolvidas por causa dos inúmeros cálculos e iterações necessárias para se chegar a uma solução satisfatória.

2.3 Programação Matemática

Dentro da ciência gerencial é necessário o uso de ferramentas que deem subsídio para análise de resultados com redução de riscos e incertezas quanto ao gerenciamento do empreendimento florestal. Assim, destacam-se as técnicas de Pesquisa Operacional (PO), os quais auxiliam o processo de tomada de decisão através da utilização de modelos matemáticos que representam a realidade e fornecem resultados baseados em um processo científico, racional e lógico.

Apesar do fato de que a implementação de cada ferramenta varia em função do tipo de problema e do ambiente considerado, a metodologia da PO utiliza seis fases: (1) formular o problema; (2) construir um modelo matemático para representar o sistema; (3) deduzir uma solução do modelo; (4) testar o modelo e a solução; (5) colocar a solução em funcionamento; e (6) estabelecer controle sobre a solução (FIGURA 3) (BELFIORE & FÁVERO, 2013).

Figura 3 - Saída de produtos madeireiros ao longo do tempo dentro de limites pré-definidos



Fonte: Adaptado de Belfiore & Fávero (2013).

2.3.1 Programação Linear

A Programação Linear (PL) tem sido classificada entre os mais importantes avanços científicos dos meados do século XX e sua aplicação está cada vez mais difundida. Em um problema de programação linear, as variáveis de decisão devem ser todas contínuas, ou seja, devem assumir quaisquer valores em um intervalo de números reais (BELFIORE & FÁVERO, 2013). O objetivo consiste em auxiliar as tomadas de decisão, levando-se em conta as diversas restrições impostas pelo problema a ser solucionado. No entanto, a PL somente é útil e aplicável para encontrar as melhores soluções em problemas que tenham linearidade em seus modelos, seguindo as premissas de: (1) aditividade (modelo expressa a soma das contribuições individuais de cada variável de decisão); (2) proporcionalidade entre a contribuição de cada variável de decisão na função objetivo; (3) divisibilidade (variáveis de decisão são contínuas); (4) não negatividade (variáveis de decisão com valores não-negativos); e (5) certeza (coeficientes da função objetivo, das restrições e os termos independentes são constantes e conhecidos com certeza) (HILLIER & LIEBERMAN, 2006; DANTZIG, 1998).

A estrutura do modelo de PL é relativamente simples, composta por uma função linear representando o objetivo e algumas funções lineares representando as restrições impostas ao problema:

$$\text{MAX ou MIN } Z = c_1x_1 + c_2x_2 + \dots + c_nx_n$$

Sujeito a:

$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n \{\leq, =, \geq\} b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n \{\leq, =, \geq\} b_2$$

$$a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n \{\leq, =, \geq\} b_m$$

$$x_1 \geq 0, x_2 \geq 0, \dots, x_n \geq 0$$

em que: Z é o valor da medida de desempenho global; x_j é o nível de atividade j (para $j = 1, 2, \dots, n$); c_i é o incremento em Z que resultaria de cada incremento unitário no nível de atividade j ; b_i é a quantidade do recurso i que se encontra disponível para alocação em atividades (para $i = 1, 2, \dots, m$); a_{ij} é a quantidade do recurso i consumido por unidade de atividade j .

O modelo é construído de maneira que formule o problema em termos de tomar decisões em relação aos níveis de atividade, onde $x_1, x_2, \dots, x_n$ são denominadas variáveis de decisão e os valores de c_j, b_i e a_{ij} são as constantes de entrada para o modelo ou, como também são conhecidos, os parâmetros do modelo (HILLIER & LIEBERMAN, 2006).

Assim, quanto a otimização, há duas abordagens principais na programação matemática: maximização de parâmetros como lucro ou utilização de algum recurso e minimização de parâmetros como custos ou utilização de algum recurso que tenha alto valor agregado e muito emprego de mão-de-obra, através dos modelos de programação matemática.

Apesar das numerosas e diversas aplicações da programação linear (estratégias, finanças, logística, marketing, engenharia, recursos humanos, dentre tantas outras), é uma de suas hipóteses, a de divisibilidade, que limita um número maior de aplicações. Na maior parte dos problemas, as variáveis de decisão fazem mais sentido se assumirem valores inteiros, como é o caso, por exemplo, do agendamento de colheita florestal, onde uma unidade de manejo é colhida por inteiro. Para solução desse tipo de problema, que exige valores inteiros, utiliza-se a técnica de programação linear inteira (PLI).

2.3.2 Programação Linear Inteira

Um modelo de otimização constitui um problema de Programação Inteira se qualquer variável não puder assumir valores contínuos, ficando condicionada a assumir valores discretos (GOLDBARG, 2005). O modelo matemático para programação inteira nada mais é que o modelo de programação linear com uma restrição adicional de que as variáveis devem ser valores inteiros.

O requisito de que variáveis tenham de ser inteiras normalmente implica maior complexidade computacional do que a oriunda de situações de não lineares de funções. Essa complexidade está associada a dois pontos, principalmente. O primeiro deles é que ter um número finito de soluções viáveis garante que o problema seja prontamente solucionável, mas números finitos podem ser significativamente grandes, conferindo cada vez mais complexidade ao modelo. O segundo ponto é que problemas de programação linear geralmente são muito mais fáceis de serem resolvidos que problemas de PI, uma vez que a eliminação de algumas soluções viáveis (aquelas não-inteiras) de um problema de programação linear o torna ainda mais difícil de ser solucionado. Isso porque o que garante que existe uma solução viável que é ótima para o problema como um todo é exatamente todas as soluções viáveis estarem presentes no modelo (HILLIER & LIEBERMAN, 2006).

Em razão desses dois pontos inconvenientes citados anteriormente, uma melhor metodologia para lidar com problemas de PI que são muito grandes para serem resolvidos de forma exata é empregar um algoritmo heurístico. Esses algoritmos são muito eficientes para problemas de maior magnitude, mas não garantem uma solução ótima. Porém, tendem a uma maior eficácia que os métodos tradicionais de programação.

2.4 Meta-heurística Algoritmo Genético

Apesar de apresentarem resultados confiáveis e consistentes, as limitações do algoritmo *branch and bound* para solução dos modelos mais complexos de programação inteira foram a principal motivação para a busca por alternativas para solução dos problemas de manejo florestal. Nesse sentido, destacam-se os algoritmos chamados de heurísticos, os quais se baseiam em um procedimento que busca encontrar uma excelente solução viável, mas não necessariamente uma solução ótima para o problema em questão (BETTINGER *et al.*, 2009). Embora não garanta a otimalidade, trabalhos como o de Rodrigues (2001) ressaltam a eficiência dos procedimentos heurísticos em fornecer soluções aceitáveis com baixo esforço computacional. Ainda, a incorporação de relações não lineares no processo quantitativo de planejamento e a geração de uma solução para um problema complexo mais rapidamente são duas importantes razões pelas quais uma heurística é selecionada para auxiliar o planejamento florestal (BETTINGER *et al.*, 2009).

Os métodos heurísticos geralmente se baseiam em ideias simples e de senso comum para buscar uma boa solução. Primeiramente é necessário que haja a geração de soluções viáveis iniciais, que na maioria das vezes são obtidas de forma aleatória ou por meio de algoritmos de geração apropriados. Um critério de parada é utilizado para testar se a busca prossegue ou não. O processo é interrompido se o critério for atendido, caso não seja, a solução corrente é alterada para apontamento de uma nova solução viável. Se encontrada, a nova solução é aceita, se não, é eliminada e o processo continua com a solução não modificada. O processo de teste do critério de parada é iniciado novamente para decidir se o processo será interrompido ou se a busca terá continuidade (RODRIGUES, 2001).


Apesar de aparentemente simples, o algoritmo heurístico precisa ser cuidadosamente adaptado para se adequar a cada problema. Os métodos heurísticos são, portanto, específicos por natureza, não atendendo a uma variedade de aplicações. Essa característica deixou de ser limitante com o desenvolvimento das meta-heurísticas, que se tornou uma das mais importantes técnicas de PO.

Uma meta-heurística é um método de resolução geral que fornece tanto uma estrutura quanto instruções gerais para desenvolvimento de um método heurístico específico que se adeque a um tipo de problema particular (HILLIER & LIEBERMAN, 2006). Enquanto a heurística é guiada por regras e ideias, visando encontrar uma boa solução, a meta-heurística representa uma combinação de procedimentos de busca com estratégias de mais alto nível,

incluindo intensificação e diversificação, buscando escapar de ótimos locais com o intuito de encontrar soluções muito próximas do ótimo global, porém sem a garantia da otimalidade.

Pela interface entre as áreas de Inteligência Artificial (IA), Inteligência Computacional (IC) e Pesquisa Operacional (PO), é possível afirmar que todos os algoritmos de busca heurística provenientes da IA e os bioinspirados da IC também podem ser chamados ou classificados como meta-heurísticas, ou seja, uma subárea da PO (FIGURA 4). Adicionalmente, verifica-se que muitos métodos de otimização, como o algoritmo Simplex e o *branch and bound*, não pertencem às áreas de IA e IC (BELFIORE & FÁVERO, 2013).

Figura 4 - Interface entre as áreas de IC, IA e PO



Fonte: Adaptado de Belfiore & Fávero (2013).


São vários os algoritmos meta-heurísticos, mas os mais comumente usados são os algoritmos genéticos (AG), a busca tabu (BT) e a *simulated annealing* (SA), os quais também apresentam grande desempenho em trabalhos dentro do manejo florestal (RODRIGUES, 2001; GOMIDE, 2009; BINOTI, 2010).

O algoritmo genético é uma ferramenta de busca e otimização que se baseiam na Teoria Darwiniana de seleção natural e reprodução genética, utilizando princípios de sobrevivência e reprodução dos indivíduos mais aptos para produzir melhores soluções a cada geração (NOGUEIRA, 2017). Se enquadram nos métodos heurísticos por possuírem a propriedade de empregar um processo adaptativo para resolução de problemas com alto grau de complexidade. Rodrigues (2001) ressalta a importância da técnica para se resolver problemas combinatoriais, como comumente encontrado nos problemas de programação inteira, e embora não garanta a otimalidade da solução, sua vantagem está ligada ao desempenho e performance computacional, além de uma relativa simplicidade no procedimento.

2.4.1 Parâmetros do Algoritmo Genético

O processo de otimização do AG dá-se início a partir de um conjunto de informações (população inicial) que pode ser adquirida de forma aleatória ou com o uso de algoritmos heurísticos construtivos, desde que sejam simples e rápidos. A cada nova iteração, é obtido uma nova população a partir da população corrente utilizando os chamados operadores genéticos básicos: seleção, *crossover* e mutação (SCOLA, 2014). Segundo Takahashi (2003), o operador de seleção replica alguns indivíduos da população e elimina alguns outros gerando uma nova população; o operador de *crossover* combina a informação de dois ou mais indivíduos gerando um novo indivíduo; e o operador de mutação gera um novo indivíduo de modo que certos filhos também adquirem características que nenhum dos pais possui (FIGURA 5).

Figura 5 - Estrutura geral do algoritmo genético



Fonte: Adaptado de Binoti (2010).

Por utilizarem técnicas de probabilidade, uma mesma população inicial com um mesmo conjunto de parâmetros pode gerar diferentes soluções a cada vez que o algoritmo genético for executado, embora seja direcionado por seleção (BINOTI, 2010).

Independente da sofisticação de um AG, existem componentes que são básicos em sua implementação (RODRIGUES, 2001).

2.4.1.1 Função objetivo

Também chamada de função de aptidão ou “*fitness*”, a função de avaliação analisa a qualidade do indivíduo e está relacionada à minimização ou maximização do valor esperado da função objetivo do problema (LOPES; TAKAHASHI, 2011). É o componente de maior importância seja qual for o algoritmo genético, porque é através dele que se mede a aproximação de um indivíduo da solução desejada ou mede quão boa é essa solução (POZO *et al.*, 2005).

2.4.1.2 População inicial

No algoritmo genético, é chamado de população o conjunto de indivíduos cogitados como solução e que é usado para formar uma nova geração de indivíduos para análise (POZO *et al.*, 2005). O tamanho dessa população inicial é um dos parâmetros que controlam a evolução do processo e corresponde ao número de pontos no espaço de busca. Geralmente, é formada a partir de indivíduos aleatórios.

2.4.1.3 Operadores de seleção

A principal função dos operadores de seleção está relacionada ao direcionamento da diversidade da população e sua velocidade de convergência. Isso ocorre através da definição de quais indivíduos serão selecionados para reprodução para formação de uma próxima população. Métodos comumente selecionados para escolher os indivíduos que estarão sujeitos a aplicação dos operadores genéticos são a roleta e o torneio.

2.4.1.3.1 Método da roleta

A escolha por esse método é baseada no valor de *fitness* dos indivíduos, de forma que os mais aptos têm uma maior probabilidade de serem selecionados para reprodução. Assim, cada indivíduo da população é representado proporcionalmente na roleta pelo seu valor de *fitness*, dando uma maior porção para aqueles com alta aptidão, enquanto aos indivíduos de aptidão mais baixa resta porções relativamente menores. A probabilidade é calculada da seguinte forma:

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j}$$

em que: p_i é probabilidade do indivíduo i ser selecionado; f_i é a avaliação do indivíduo i na população corrente; e N é o número de indivíduos na população.

Neste método, um dos inconvenientes encontrados é o maior tempo de processamento por ser um método que exige duas passagens por todos os indivíduos do conjunto (POZO *et al.*, 2005).

2.4.1.3.2 Método por torneio

Essa técnica seleciona dois indivíduos de forma aleatória e escolhe o mais apto com base na função de avaliação de cada fase (LOPES; TAKAHASHI, 2011). Basicamente, há um torneio entre um grupo de n indivíduos, onde n é igual ou maior que dois, aleatoriamente selecionados da população. Dessa forma, o indivíduo com o maior valor de *fitness* no grupo é selecionado para reprodução, enquanto que os demais são descartados.

Além da vantagem de ser um dos modelos mais simples para implementação computacional com bons resultados, o método por torneio impossibilita convergência prematura, impede a estagnação, elimina a necessidade de um esforço computacional adicional e tem inspiração biológica no processo (CASTRO, 2001).

2.4.1.4 Operadores genéticos

Os operadores genéticos são mecanismos que asseguram a evolução dos indivíduos. Dessa forma, a partir de uma população inicial são criadas novas populações ou gerações de indivíduos melhorados (RODRIGUES, 2001).

2.4.1.4.1 Operador crossover


O *crossover* é encarregado pelo cruzamento, ou seja, troca de materiais genéticos, entre os indivíduos previamente selecionados através de um critério, o que proporciona a recombinação de genes para a formação de indivíduos (GOMIDE, 2009). Dessa forma, novos indivíduos podem ser formados pelo cruzamento de indivíduos diferentes. Lopes e Takahashi (2011) salientam que o operador *crossover* busca solução a partir de indivíduos já existentes, o que os autores chamam de *exploitation*.

A probabilidade de cruzamento dos indivíduos pais é chamada de taxa de *crossover*. Para que haja o cruzamento de dois indivíduos pais, um número aleatório

selecionado entre 0 e 1 deve ser menor que a taxa de *crossover*. Esse processo se repete até o tamanho da população ser restabelecido (RODRIGUES, 2001).

Os tipos entre os mais comuns de *crossover* nos algoritmos genéticos são de um único ponto e o uniforme. No *crossover* de um ponto os dois indivíduos pais selecionados para reprodução têm seus genes trocados a partir de um ponto de ruptura que é escolhido aleatoriamente (FIGURA 6). No caso do cruzamento uniforme há a necessidade de se determinar de qual dos pais serão copiadas as características para criação do filho (LOPES; TAKAHASHI, 2011).

Figura 6 - Crossover de um ponto gerando novos indivíduos




Fonte: Adaptado de Rodrigues (2001).

2.4.1.4.2 Operador de mutação

A mutação é um evento que acontece aleatoriamente na natureza onde um gene é trocado por outro gerando uma nova estrutura genética (GOMIDE, 2009). O operador de mutação altera o valor de alguns alelos do cromossomo, como demonstrado na figura 7, o que confere diversidade à população. Diferente do operador *crossover*, o operador de mutação busca uma solução em regiões factíveis ainda não avaliadas do campo de busca (*exploration*) (LOPES; TAKAHASHI, 2011). A geração de um bom indivíduo não é certa, como também ocorre na reprodução, assim como não há garantia de sua permanência nas próximas gerações, a depender exclusivamente dos operadores de seleção e do seu valor de *fitness* (GOMIDE, 2009).

Figura 7 - Exemplo de funcionamento do operador genético de mutação



Fonte: Adaptado de Gomide (2009).

2.4.1.5 Elitismo


Seleção elitista força o algoritmo genético a reter alguns dos melhores indivíduos em cada geração, visando evitar a perda de bons indivíduos quando submetidos a *crossover* ou mutação. Esse método garante que os melhores indivíduos passem para a próxima geração preservando suas melhores características originais (LOPES; TAKAHASHI, 2011).

3 MATERIAL E MÉTODOS

3.1 Base de Dados

A área utilizada para as simulações foi de 4.269,29 ha, distribuída em 120 talhões, com uma distribuição irregular para as classes de idades existentes no povoamento (FIGURA 8).

Figura 8 - Distribuição de área de plantio por classe de idade



Fonte: Do autor, 2017.

Os valores de custo e receita foram obtidos do trabalho de Araújo Júnior (2012) (TABELA 1).

Tabela 1 - Custos empregados para cálculo do VPL de cada solução obtida pelo AG

Idade (anos)	Custos silviculturais(R\$.ha ⁻¹)	Preço de venda da madeira(R\$.m ⁻³)
1	4059,05	20,00
2	1627,81	20,00
3	757,95	20,00
4	88,12	30,00
5	88,12	40,00
6	88,12	80,00
7	88,12	80,00

Fonte: Adaptada de Araújo Júnior (2012).

3.2 Descrição do Problema de Planejamento Florestal

O problema proposto tem como objetivo encontrar um cenário de planejamento da produção florestal que retorne o máximo Valor Presente Líquido (VPL), cuja formulação é dada por:

$$VPL = \sum_{j=0}^n R_j(1+i)^{-j} - \sum_{j=0}^n C_j(1+i)^{-j}$$

em que: C_j é custo no final do ano j ; R_j é receita no final do ano j ; i é taxa de desconto; j é o período de tempo considerado; n é a duração do projeto, em ano.

O modelo matemático de otimização considerou a estrutura proposta por Johnson e Scheurman (1977):

$$\text{Max VPL} = \sum_{i=1}^M \sum_{j=1}^P \text{VPL}_{ij} \cdot X_{ij} \quad (1)$$

Sujeito a

$$\sum_{i=1}^M \sum_{j=1}^P X_{ij} = 1 \quad (2)$$

$$\sum_{i=1}^M \sum_{j=1}^P V_{ij} X_{ij} \geq D_{\min_k} \quad (3)$$

$$\sum_{i=1}^M \sum_{j=1}^P V_{ij} X_{ij} \leq D_{\max_k} \quad (4)$$

$$X_{ij} \in \{0,1\} \quad (5)$$

em que: VPL_{ij} é o VPL da unidade de manejo i segundo o regime de manejo j ; X_{ij} é a variável de decisão do tipo binária, recebendo valor 1 quando a alternativa de manejo j é assinalada à unidade de manejo i ou 0, caso contrário; M é o número total de unidades de manejo; P é o número total de alternativas de manejo para a unidade de manejo i ; k é o período do horizonte de planejamento; $D_{\min_k}$ e $D_{\max_k}$ são, respectivamente, a demanda mínima e máxima de madeira (m^3) no período k do horizonte de planejamento.

A função objetivo (1) busca maximizar o retorno financeiro e está sujeita à restrição binária (5), restrição de integridade (2), onde cada uma das unidades de manejo só devem receber uma única prescrição e restrição de demanda volumétrica, onde o volume colhido durante o ano deveria respeitar um limite mínimo (3) e máximo (4). Para o presente trabalho foi estabelecida uma demanda anual máxima de 160.000 m^3 e mínima de 140.000 m^3 , permitido o corte das unidades de manejo com idades entre 5 e 7 anos e definido um horizonte de planejamento com 16 anos. A taxa de juros considerada foi de 8%.

3.3 Algoritmo Genético

A função de aptidão do AG utilizado levou em consideração o método de penalidades, conforme Gomide *et al.* (2009), Rodrigues (2004) e Binoti *et al.* (2014). O valor adotado nesse trabalho foi de R\$ 500,00/m³ por volume excedido ou faltante em relação ao intervalo pré-estabelecido pelas restrições impostas ao modelo. Assim, a equação que representa a função objetivo é dada por:

$$\text{Max VPL} = \sum_{i=1}^M \sum_{j=1}^P \text{VPL}_{ij} \cdot X_{ij} - P \cdot \sum_{k=1}^T d_k$$

em que: P é a penalidade em R\$/m³ de madeira; T é o tempo total do planejamento; e d_k é o valor absoluto do desvio volumétrico de madeira em m³ em um período k do horizonte de planejamento.

3.3.1 Avaliação dos parâmetros do Algoritmo Genético

Foram avaliadas 16 diferentes combinações de parâmetros do AG (QUADRO 1), com o objetivo de chegar à melhor delas. Em relação à seleção dos pais para cruzamento, avaliou-se o método da roleta e o método do torneio. No processo de reprodução considerou-se o cruzamento com um ponto de ruptura e o cruzamento uniforme. A taxa de cruzamento considerada foi de 80%, conforme Linden (2008). Já para o processo de mutação avaliou-se a mutação aleatória e a mutação gene a gene, sempre com taxa de mutação igual a 1%. Ainda, a seleção dos indivíduos para a próxima geração foi feita com e sem elitismo.

Quadro 1 - Combinações dos parâmetros do algoritmo genético testadas

Combinação	Elitismo	Cruzamento	Seleção	Mutação	Abreviação
1	Com	1 ponto	Roleta	Aleatória	R_1_A_C
2				Gene a gene	R_1_G_C
3			Torneio	Aleatória	T_1_A_C
4				Gene a gene	T_1_G_C
5		Uniforme	Roleta	Aleatória	R_U_A_C
6				Gene a gene	R_U_G_C
7			Torneio	Aleatória	T_U_A_C
8				Gene a gene	T_U_G_C
9	Sem	1 ponto	Roleta	Aleatória	R_1_A_S
10				Gene a gene	R_1_G_S
11			Torneio	Aleatória	T_1_A_S
12				Gene a gene	T_1_G_S
13		Uniforme	Roleta	Aleatória	R_U_A_S
14				Gene a gene	R_U_G_S
15			Torneio	Aleatória	T_U_A_S
16				Gene a gene	T_U_G_S

Fonte: Do autor, 2017.


Para análise dos resultados, considerou-se o melhor indivíduo de cada repetição, independente da geração na qual o mesmo foi obtido.

Inicialmente foram testadas todas as configurações com 50 indivíduos na população inicial e critério de parada em 100 gerações. Posteriormente, estabelecida a melhor combinação dos parâmetros, foram testadas populações com 20, 50 e 80 indivíduos e critério de parada com 100, 300 e 500 gerações. O principal objetivo de testar tamanhos variados foi analisar melhor de que forma esse parâmetro afeta a qualidade da resposta final e sua eficiência quanto ao tempo de processamento.

3.4 Processamento

O processamento de todas as configurações foi efetuado através do aplicativo MeP - *Metaheuristic for forest Planning* (FIGURA 9), em desenvolvimento pelo Laboratório de Pesquisa Operacional e Modelagem Florestal (LPM) da Universidade Federal de Minas Gerais.

Figura 9 - Layout do MeP



Fonte: Do autor, 2017.

3.5 Análise dos resultados

Os dados de *fitness* e tempo de processamento foram analisados a partir do valor mínimo, médio e máximo de cada configuração avaliada, proveniente de 30 repetições. Na análise foi aplicado o teste não paramétrico desenvolvido por Kruskal e Wallis (1952), o qual utiliza *ranks* dos dados ao invés de seus valores brutos para o cálculo da estatística de teste.

Assim como Rodrigues (2001), para analisar a acurácia do resultado da melhor combinação de parâmetros, o mesmo foi comparado à solução gerada pelo modelo de programação inteira *branch and bound* processado no *software* Lingo, interrompido após 96 horas de processamento. Dessa forma, a eficácia (*Ef*) foi calculada segundo a fórmula:

$$Ef = \frac{f_{AG}}{f_o} \times 100$$

em que: f_{AG} é o valor da melhor solução obtida pelo algoritmo genético (R\$); e f_o é o valor da melhor solução gerada pelo algoritmo de *branch and bound* (R\$).

4 RESULTADOS E DISCUSSÃO

A eficácia das combinações variou de 38,1% (combinação 13) a 95,7% (combinação 4), o que ressalta a importância da correta escolha da configuração dos parâmetros na performance do algoritmo (TABELA 2). A solução encontrada pelo algoritmo de *branch and bound* apresentou um valor igual a R\$ 31.964.100.


Tabela 2 - Valores máximo, médio, mínimo, desvio padrão e eficácia dos *fitness* gerados pelas combinações entre os parâmetros do algoritmo genético

Combinação	Máximo (R\$)	Médio (R\$)	Mínimo (R\$)	Desvio (R\$)	Eficácia (%)
4 - T_1_G_C	30.582.271	30.336.526	29.950.852	127.846	95,7
2 - R_1_G_C	30.514.441	30.268.322	29.981.728	130.474	95,5
6 - R_U_G_C	30.514.023	30.267.666	29.991.120	117.126	95,5
8 - T_U_G_C	30.528.960	30.280.900	29.922.636	122.637	95,5
16 - T_U_G_S	30.527.415	30.065.664	29.665.328	177.517	95,5
12 - T_1_G_S	30.385.421	29.983.441	29.639.960	169.485	95,1
1 - R_1_A_C	30.290.620	28.666.138	24.667.924	1.502.946	94,8
11 - T_1_A_S	30.228.176	26.868.620	10.451.915	3.848.382	94,6
3 - T_1_A_C	30.187.268	26.824.866	19.368.386	3.123.281	94,4
5 - R_U_A_C	27.280.659	9.252.245	-14.504.788	9.732.754	85,3
9 - R_1_A_S	25.753.525	4.835.537	-9.627.649	7.916.626	80,6
7 - T_U_A_C	25.704.270	9.310.407	-20.566.389	9.912.923	80,4
15 - T_U_A_S	23.168.314	1.061.475	-21.316.736	11.776.938	72,5
10 - R_1_G_S	19.402.347	2.911.672	-14.093.762	7.511.151	60,7
14 - R_U_G_S	14.542.186	-4.510.935	-19.343.447	9.561.605	45,5
13 - R_U_A_S	12.185.194	-31.352.348	-57.713.235	15.575.244	38,1

Fonte: Do autor, 2017.

Ainda sobre a expressiva variação entre os *fitness* gerados pelas combinações testadas, a Figura 10 mostra a produção em volume ao longo dos 16 anos de horizonte de planejamento considerando a configuração com a pior eficácia, combinação 13 (FIGURA 10a), e a de melhor eficácia, combinação 4 (FIGURA 10b). A melhor solução obtida pela combinação 4 atendeu à restrição de regulação de acordo com a demanda anual definida, enquanto a melhor solução pela combinação 13 apresentou irregularidades em termos de produção florestal ao longo dos anos. A diferença mostrada confirma que a configuração correta dos parâmetros da metaheurística é relevante para eficiência e funcionamento dos algoritmos genéticos.


Figura 10 – Volumes obtidos pela combinação 13 (a) e pela combinação 4 (b) distribuídos ao longo dos 16 anos do horizonte de planejamento.




Fonte: Do autor, 2017.


Nesse contexto de comparação entre as combinações é importante avaliar o comportamento dos resultados ao longo das gerações (FIGURA 11). Pode-se notar que ocorreram diferenças significativas em relação à evolução das soluções obtidas em cada configuração. As figuras (i), (j), (m) e (n) mostram que não houve uma melhoria contínua das soluções encontradas pelo algoritmo ao longo das gerações, variando em torno de um valor médio abaixo de zero. Isso pode ser associado principalmente à combinação do método de seleção por roleta e a não utilização do elitismo. Em observação aos resultados obtidos nesse trabalho, é possível notar que o mecanismo de seleção tanto por roleta quanto por torneio apresenta diferentes comportamentos quando há ou não a presença do elitismo. Apesar disso, os demais gráficos mostraram tendência a obtenção de indivíduos mais aptos com o passar das gerações.

Figura 11 - Estrutura da evolução das buscas pelos valores médios de *fitness* obtidos pelo AG nas 16 combinações testadas ao longo de 100 gerações.







(c)




(d)




(e)




(f)




(g)




(h)




(i)




(j)




(k)




(l)




(m)



(n)



(o)



(p)

Fonte: Do autor, 2017.

Os resultados do teste Kruskal Wallis para comparar as combinações entre os métodos de seleção, cruzamento, mutação e elitismo apresentaram diferenças estatísticas significativas entre si para o problema analisado a um nível de significância igual a 5% (TABELA 3). A combinação 4 não foi estatisticamente diferente da combinação 8, que por sua vez não apresentou diferenças estatisticamente significativas em relação às combinações 2 e 6. O tempo de processamento não apresentou grandes variações, sendo 2,47, 2,78, 2,52 e 2,43 minutos para as combinações 2, 4, 6 e 8, respectivamente. Apesar da semelhança, a combinação 4 tende a ser mais onerosa quanto ao tempo.

Tabela 3 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis *fitness* para as 16 combinações dos parâmetros.

Combinação	rank	Fitness médio (R\$)	
4 - T_1_G_C	428,53	30.336.526	a
8 - T_U_G_C	409,70	30.280.900	ab
2 - R_1_G_C	405,60	30.268.322	b
6 - R_U_G_C	405,53	30.267.666	b
16 - T_U_G_S	344,20	30.065.664	c
12 - T_1_G_S	325,57	29.983.441	c
1 - R_1_A_C	274,83	28.666.138	d
11 - T_1_A_S	255,13	26.868.620	d
3 - T_1_A_C	255,00	26.824.866	d
7 - T_U_A_C	150,17	9.310.407	e
5 - R_U_A_C	148,13	9.252.245	e
9 - R_1_A_S	122,30	4.835.537	f
10 - R_1_G_S	114,70	2.911.672	f
15 - T_U_A_S	107,70	1.061.475	f
14 - R_U_G_S	78,50	-4.510.935	g
13 - R_U_A_S	22,40	-26.917.572	h

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

Os métodos de seleção por torneio e por roleta apresentaram diferenças estatisticamente significativas entre si pelo teste de Kruskal Wallis a um nível de 5% de probabilidade, sendo que o primeiro método apresentou melhores resultados (TABELA 4). Lopes e Takahashi (2011) corroboram com o resultado encontrado nesse trabalho e ainda intitulam a seleção por roleta como o “pior método existente”. A menos que haja uma boa razão para utilização de outro método, o torneio é certamente a melhor das escolhas (RENNARD, 2007; SIVANANDAM; DEEPA, 2008), por ser o operador de seleção mais simples de ser implementado e ainda assim ser capaz de gerar resultados muito bons (BENTO; KAGAN, 2008). No entanto, os resultados apresentados mostram que há mudança de comportamento dos métodos de seleção quando há presença ou não do mecanismo de substituição dos indivíduos para a geração seguinte, o elitismo. Na Tabela 2 é possível observar que as combinações sem elitismo apresentaram melhores resultados quando utilizado o método de seleção por torneio, porém, quando analisados somente os dados com elitismo o método por roleta mostrou melhor performance.

Tabela 4 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis *fitness* para os 2 operadores de seleção testados.

Métodos de Seleção	rank	Fitness médio
		(R\$)
Torneio	284,50	23.091.487 a
Roleta	196,50	9.346.634 b

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

Utilizando-se do método de elitismo em um problema de planejamento florestal, Rodrigues *et al.* (2004) testou cinco métodos de seleção, Boltzman, escalonamento, ranqueamento, roleta e torneio, e o último foi o que gerou os piores resultados. Segundo o autor, a principal causa foi a aleatoriedade do método, não utilizando nenhuma informação do problema para seleção dos indivíduos ao longo da busca. Gomide *et al.* (2009) observaram o mesmo comportamento dos resultados, onde o método por roleta gerou melhores resultados que o método por torneio. Os autores alegam que o operador de seleção por roleta obteve uma maior diversidade de indivíduos ao longo das iterações e, por isso o fato de se obter as melhores respostas em *fitness*.

Os tipos de cruzamento também apresentaram diferenças estatística significativas entre si pelo teste de Kruskal Wallis a um nível de 5% de probabilidade (TABELA 5). O teste apontou o mecanismo de 1 ponto como superior ao uniforme, principalmente por apresentar apenas uma posição de ruptura, diferente do método uniforme que segue uma probabilidade para determinar de qual dos pais serão copiadas as características para geração do filho, possibilitando um maior número de cortes para cruzamento. No geral, quanto maior for o número de rupturas, menor a semelhança entre os pais e filhos, o que dificulta a convergência do algoritmo (COSTA FILHO; POPPI, 1999).

Tabela 5 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis *fitness* para os 2 tipos de cruzamento testados.

Tipo de Cruzamento	rank	Fitness médio
		(R\$)
1 ponto	272,71	22.586.890 a
Uniforme	208,29	9.851.231 b

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

Quando o problema apresenta genes com comportamento epistático, ou seja, exerce ação inibitória, o cruzamento uniforme deve ser evitado. Na florestal, isso pode ser dado como verdade, já que para respeitar-se as restrições, a seleção de uma unidade para corte depende da prescrição adotada pelas outras unidades de manejo. Por outro lado, tem sido

mostrado que um único ponto de cruzamento pode ser problemático por talvez não ser suficiente para a criação de boas combinações. Nos casos em que esse problema pode acontecer, um *crossover* de 2 pontos é geralmente mais recomendado (RENNARD, 2007). Este tipo de cruzamento segue a mesma estrutura de funcionamento do tipo de 1 ponto, testado nesse trabalho.

Os tipos de mutação também apresentaram diferenças estatísticas significativas entre si pelo teste de Kruskal Wallis a um nível de 5% de probabilidade, apontando o método de gene a gene como melhor (TABELA 6). O mecanismo de mutação gene a gene percorre cada uma das características associando um número aleatório que indica se o gene será ou não mutado seguindo uma probabilidade pré-definida, direcionando melhor a população a uma maior diversidade, e quanto maior essa diversidade, maiores são as chances de se obter indivíduos mais adaptados ao problema. A diferença entre os tipos de mutação também pode ser observada na Figura 9 pela comparação entre os gráficos (e) e (g) e os gráficos (f) e (h). Os dois primeiros tendem a encontrar melhores resultados a cada nova geração por estar sendo utilizado o elitismo. Porém, seria necessário um número de gerações significativamente maior que o testado para se alcançar bons resultados. Os gráficos (f) e (h) por sua vez, mostram uma convergência em uma boa solução viável em um número muito menor de gerações (FIGURA 10).

Tabela 6- Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis *fitness* para os 2 tipos de cruzamento testados.

Tipo de Mutação	rank	Fitness médio (R\$)
Gene a gene	314,04	22.450.407 a
Aleatória	166,96	9.987.715 b

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

As combinações que tiveram o elitismo introduzido se diferiram estatisticamente daquelas que não possuíam essa característica (TABELA 7), sendo a utilização da técnica mais recomendada. Muitos indivíduos podem ser perdidos se eles não forem selecionados para reprodução ou se eles forem destruídos pelo cruzamento ou mutação (MITCHELL, 1999; MENDES, 2013). O elitismo é aplicado afim de garantir a permanência do melhor indivíduo encontrado a cada nova geração.

Tabela 7 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis *fitness* para os 2 tipos de cruzamento testados.

		<i>Fitness médio</i> (R\$)
Elitismo	Rank	
Com	309,69	24.400.884 a
Sem	171,31	8.037.238 b

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

Apesar da garantia de não se perder o melhor indivíduo durante o processo evolutivo, onde o resultado não piora, o elitismo possui a desvantagem de possibilidade de forçar a busca, pela presença de mais uma cópia do melhor indivíduo, na direção de algum ponto ótimo local que tenha sido descoberto antes do global. Nesses casos, considerar não se utilizar o parâmetro de elitismo pode ser interessante, uma vez que a melhor solução encontrada durante a evolução é guardada, para no final designá-lo como indivíduo ótimo encontrado, mesmo que ele não esteja presente na última geração da execução.

Identificada a melhor combinação entre os parâmetros elitismo, método de seleção, tipo de cruzamento e tipo de mutação, constatou-se variações entre as combinações entre tamanho da população inicial e número de gerações de 95,3% (combinação 1) a 97,1% (combinação 6), resultado obtido em menos de 12 minutos (TABELA 8). Silva *et al.* (2009) obtiveram menor e maior eficácia de 96,6% e 98,41%, respectivamente, enquanto Rodrigues *et al.* (2004) encontraram variação de eficácia entre 90,0% e 98,48% quando comparados diferentes tamanhos de população inicial.

Tabela 8 - Valores máximo, médio, mínimo, desvio padrão e eficácia dos *fitness* gerados e tempo de processamento das combinações entre tamanho da população inicial e número de gerações.

Combinação	Máximo (R\$)	Médio (R\$)	Mínimo (R\$)	Desvio (R\$)	Eficácia (%)	Tempo (min)
1 - 20_100	30.460.748	30.236.810	29.987.893	134.400	95,30	0,67
2 - 20_300	30.637.644	30.421.669	30.165.908	98.515	95,85	1,85
3 - 20_500	30.766.261	30.540.704	30.356.725	117.983	96,25	2,91
4 - 50_100	30.517.447	30.332.460	30.122.940	98.200	95,47	2,62
5 - 50_300	30.780.028	30.538.297	30.305.287	111.714	96,30	7,32
6 - 50_500	31.024.769	30.690.734	30.482.052	140.229	97,06	11,74
7 - 80_100	30.586.855	30.352.364	30.139.824	109.371	95,69	6,08
8 - 80_300	30.765.532	30.614.299	30.294.983	97.884	96,25	16,91
9 - 80_500	30.957.746	30.738.711	30.515.949	110.609	96,85	27,57

Fonte: Do autor, 2017.

Os resultados do teste Kruskal Wallis para comparar as combinações entre o tamanho da população inicial e o número de gerações apresentaram diferenças estatística

significativas entre si para o problema analisado a um nível de significância igual a 5% (TABELA 9). Os resultados do teste mostraram que a combinação de número 9, o qual contava com 80 indivíduos na população inicial e 500 gerações como critério de parada, não se diferiu estatisticamente da combinação de número 6 (50 indivíduos na população inicial e 500 gerações), que por sua vez não se diferiu estatisticamente da combinação de número 8 (80 indivíduos e 300 gerações). Apesar da semelhança estatística, a combinação de número 6 demandou um menor tempo de processamento, pois gerou um bom resultado em 11,74 minutos enquanto o tempo gasto pelas combinações 8 e 9 foram de 16,91 e 27,57 minutos, respectivamente.

Tabela 9 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado às combinações entre tamanho de população inicial e número de gerações.

Combinação	rank	Fitness médio	
		(R\$)	
9 - 80_500	230,37	30.738.711	a
6 - 50_500	211,63	30.690.734	ab
8 - 80_300	189,37	30.614.299	b
3 - 20_500	155,57	30.540.704	c
5 - 50_100	154,77	30.538.297	c
2 - 20_300	101,40	30.421.670	d
7 - 80_100	73,03	30.352.364	e
4 - 50_100	63,70	30.332.460	e
1 - 20_100	39,67	30.236.810	f

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

Pelo teste de Kruskal Wallis a um nível de significância de 5%, a população com apenas 20 indivíduos se diferiu das demais combinações, 50 e 80 indivíduos, que por sua vez não diferiram entre si (TABELA 10). Esse parâmetro deve ser escolhido cautelosamente de modo a permitir que o algoritmo seja capaz de explorar todo o campo de busca. Quando a população é muito pequena o espaço de busca é limitado, provocando uma queda no desempenho. Porém, quanto maior a população, maior o tempo de processamento e os recursos computacionais necessários (RODRIGUES *et al.*, 2004).

Tabela 10 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis *fitness* para os diferentes tamanhos de população testados.

Tamanho da População	rank	Fitness médio	
		(R\$)	
80	164,26	30.568.458	a
50	143,37	30.520.497	a
20	98,88	30.399.728	b

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

Nesse trabalho, como as duas primeiras combinações, 50 e 80 indivíduos, não se diferiram entre si estatisticamente, a população com 50 indivíduos pode ser mais vantajosa por exigir menores esforços computacionais e tempo de processamento.

Rodrigues *et al.* (2004) avaliou populações com 25 a 100 indivíduos e concluiu que tamanhos de 75 a 100 proporcionam melhores eficácias para o AG, reforçando a ideia de que o fator população inicial foi o que exerceu maior influência na aproximação da resposta obtida pelo algoritmo genético da resposta encontrada pelo algoritmo exato. Da mesma forma, Silva *et al.* (2009) encontraram maior eficácia para os maiores tamanhos de população inicial, observando tendência de piora do desempenho em termos de eficácia com a redução do tamanho da população. Assim, é possível inferir que uma população de maior extensão pode preservar melhor a diversidade, evitando a convergência prematura (RENNARD, 2007). Por fim, para todo e qualquer problema, o tamanho da população irá depender de sua complexidade (SIVANANDAM; DEEPA, 2008).

Houve diferenças estatísticas significativas pelo teste de Kruskal Wallis a um nível de significância de 5% entre os números de gerações testados (TABELA 11). O critério de parada considerando 500 gerações apresentou melhores resultados que as demais combinações (300 e 100 gerações). Isso já era esperado, uma vez que valores muito baixos podem diminuir a eficácia do algoritmo pela redução do número de soluções viáveis encontradas nesse menor intervalo, diminuindo, assim, as chances de encontrar solução de melhor qualidade entre as soluções candidatas. Por outro lado, valores muito altos, apesar de aumentar as chances de encontrar uma solução de melhor qualidade, podem depreciar a eficiência do AG, causando depreciação no tempo de processamento da solução (RODRIGUES *et al.*, 2004).

Tabela 11 - Resumo da análise estatística não paramétrica Kruskal Wallis aplicado nas variáveis *fitness* para os diferentes tamanhos de população testados.

Número de Gerações	<i>Fitness</i> médio	
	<i>rank</i>	(R\$)
500	199,19	30.656.717 a
300	148,51	30.524.755 b
100	58,80	30.307.212 c

Médias seguidas pelas mesmas letras não apresentam diferenças estatisticamente significativas ($p < 0,05$). Fonte: Do autor, 2017.

5 CONCLUSÃO

A qualidade das soluções obtidas com a metaheurística algoritmo genético é dependente da seleção de uma boa configuração de seus parâmetros.

A melhor combinação de parâmetros apontada pelo ranqueamento foi a que tinha como método de seleção o torneio, mutação do tipo gene a gene, utilização de elitismo, tipo de cruzamento de 1 ponto, população inicial com 50 indivíduos e critério de parada com 500 gerações.

REFERÊNCIAS

- ARCE, J. E. **Um sistema de programação do transporte principal de multiprodutos florestais visando a minimização de custos**. 1997. 98 f. Dissertação (Mestrado em Engenharia Florestal). Universidade Federal do Paraná, Curitiba, 1997.
- ARAÚJO JÚNIOR, C. A. **Simulação multiagentes aplicada ao planejamento da produção florestal sustentável**. 2012. 75 f. Dissertação (Mestrado em Ciências Florestais). Universidade Federal de Viçosa, Viçosa – MG, 2012.
- AUGUSTYNICZIK, A. L. D. **Planejamento florestal otimizado considerando áreas mínimas e máximas operacionais de colheita**. 2014. 185 f. Dissertação (Mestrado em ciências florestais). Universidade Federal do Paraná, Curitiba, 2014.
- BASTOS, R. M. **O Planejamento de alocação de recursos em sistemas multiagentes**. 1998. 267 f. Tese (Doutorado em Ciência da Computação) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 1998.
- BELFIORE, P.; FÁVERO, L. P. **Pesquisa operacional para cursos de engenharia**. Rio de Janeiro: Elsevier, 2013. 545 p.
- BENTO, E. P.; HAGAN, N. Algoritmos genéticos e variantes na solução de problemas de configuração de redes de distribuição. **Revista Controle & Automação**, v. 19, n. 3, p. 302 – 315, 2008.
- BETTINGER, P.; BOSTON, K.; SIRY, L. P.; GREBNER, R. L. **Forest management and planning**. London: Academic, 2009. 331 p.
- BINOTI, D. H. B. **Estratégias de regulação de florestas equiâneas com vistas ao manejo da paisagem**. 2010. 159 f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, 2010.
- BINOTI, B. H. B.; BINOTI, M. L. M.; LEITE, H. G.; GLERIANI, J. M.; RIBEIRO, C. A. A. S. Inclusão e influência de características espaciais em modelos de regulação florestal. **Cerne**, Lavras, v.20, n. 1; p. 157-164, 2014.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: Perguntas e respostas**. 4. ed. Viçosa: UFV, 2013. 605 p.
- CARVALHO, K. H. A.; SILVA, M. L.; LEITE, H. G.; BINOTI, D. H. B.; SILVA, L. F. Influência da taxa de juros e do preço da madeira em modelos de regulação florestal. **Pesquisa Florestal Brasileira**, Colombo, v. 35, n. 82, p. 143-151, jun. 2015.
- CASTRO, R. E. **Otimização de estruturas com multi-objetivos via algoritmos genéticos**. 2001. 226 f. Tese (Doutorado em Ciências em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.
- CASTRO, R. R. **Regulação de florestas equiâneas incluindo restrições de adjacência**. 2007. 74 f. Dissertação (Mestrado em Ciência Florestal). Universidade Federal de Viçosa, Viçosa, 2007.

CHIAVENATO, I. **Introdução à teoria geral da administração**: uma visão abrangente da moderna administração das organizações. 7. ed. rev. e atual. – Rio de Janeiro: Elsevier, 2003. 634p.

COSTA FILHO, P. A.; POPPI, R. J. Algoritmo genético em química. **Química Nova**, v. 22, n. 3, p. 405 – 411, 1999.

DAVIS, K. P. **Forest management: regulation and valuation**. 2.ed. New York: McGraw-Hill, 1966. 519 p.

DANTZIG, G. B. **Linear programming and extensions**. Princeton University Press, New Jersey, 1998. 633p.

GOLDBARG, M. C. **Otimização combinatória e programação linear: modelos e algoritmos**. Rio de Janeiro: Elsevier, 2005. 519 p.

GOMIDE, L. R. **Planejamento florestal espacial**. 2009. 256 f. Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 2009.

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

HILLIER, F. S.; LIEBERMAN, G. J. **Introdução à pesquisa operacional**. 8. ed. São Paulo: MacGraw-Hill, 2006. 850 p.

JOHNSON, K. N.; SCHEURMAN, H. L. Techniques for prescribing optimal timber harvest and investment under different objectives - discussion and synthesis. **Forest Science**, Bethesda, v. 18, n. 1, p. 1-31, 1977.

KRUSKAL, W. H.; WALLIS, W. A. Use of *ranks* in one-criterion variance analysis. **Jornal of the American Statistical Association**. Chicago, v. 47, n. 260, p. 583-621, 1952.

LINDEN, R. **Algoritmos genéticos**: uma importante ferramenta da Inteligência Computacional. 2 ed. Rio de Janeiro: Brasport, 2008. 401 p.

LOPES, H. S.; TAKAHASHI, R. H. C. **Computação evolucionária em problemas de engenharia**. Curitiba, PR: Omnipax, 2011. 385 p.

MACHADO, C. C. **Colheita florestal**. Viçosa: UFV, 2008. 501 p.

MAGALHÃES, J. G. S. **Prognose e regulação de florestas de eucalipto utilizando modelo de crescimento e inteligência computacional**. 2014. 77 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2014.

MENDES, J. B. **Uma abordagem multiobjectivo para o problema de despacho de caminhões em minas a céu aberto**. 2013. 133 f. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2013.

MITCHELL, M. **An introduction to genetic algorithms**. London: Massachusetts Institute of Technology, 1999. 162 p.

NOLASCO, F. G. **Diagnóstico solução para problemas de mudanças de planejamento em sistemas computacionais de gestão florestal**. 2012. 75 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.

NOGUEIRA, V. N. **Algoritmo genético compacto em dominância para seleção de variáveis**. 2017. 64 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Goiás, Goiânia, 2017.

OLIVEIRA, D. P. R. **Planejamento estratégico: conceitos, metodologia e práticas**. 26. ed. – São Paulo: Atlas, 2009. 331p.

POZO, A.; CAVALHEIRO A. F.; ISHIDA, C.; SPINOSA, E.; RODRIGUES E. M. **Computação evolutiva**. Curitiba: Universidade Federal do Paraná, 2005. 61 p.

RENNARD, J. P. **Handbook of research on nature-inspired computing for economic and management**. London: Idea Group Reference, 2007. 998 p.

RODRIGUES, F. L. **Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais**. 2001. 255 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2001.

RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. N.; SOUZA, A. L. SILVA, G. F. Metaheurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, Viçosa, v. 28, n. 2, p. 233-245, 2004.

RODRIGUES, L. R.; SILVA, F. S.; LEITE, H. G.; XAVIER, A. C.; PEZZOPANE, J. E. M. Um modelo de regulação florestal e suas implicações na formulação e solução de problemas com restrições de recobrimento. **Revista Árvore**, Viçosa, v.30, n.5, p.769-778, 2006.

SCHEIDER, P. R. **Manejo Florestal: planejamento da produção florestal**. Santa Maria: Departamento de Ciências Florestais da Universidade Federal de Santa Maria, 2009. 501 f.

SCOLA, L. A. **Otimização multiobjetivo evolutiva da operação de sistemas de reservatórios multiusos**. 2014. 122. Tese (Doutorado em Engenharia Elétrica) - Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2014.

SCOLFORO, J. S. R. **Modelagem do crescimento e da produção de florestas plantadas e nativas**. UFLA/FAEPE, Lavras, 1998, 451 p.

SILVA, G. F., PIASSI, L. C., MORA, R., MARTINS, L., TEIXEIRA, A. F. Metaheurística algoritmo genético na solução de modelos de planejamento florestal. **Revista Brasileira de Ciências Agrárias**, Recife, v. 4, n. 2, p. 120-166, 2009.

SILVA, G. F. **Problemas no uso de programação matemática e simulação em regulação florestal**. 2001. 100f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2001.

SIVANANDAM, S. N.; DEEPA, S. N. **Introduction to genetic algorithms**, New York: Spring, 2008. 453 p.

TAKAHASHI, R. H. C.; VASCONCELOS, J. A.; RAMIREZ, J. A.; KRAHENBUHL, L. A. Multi-objective Methodology for Evaluating Genetic Operators. **IEEE Transactions on Magnetics**, v. 39, n. 3, p. 1321-1324, 2003.

WERNEBURG, M. A. P. **Planejamento em grandes empresas florestais no Brasil**. 2015. 95 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2015.