



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

MARCOS FÁVERO COSTA

**APLICAÇÃO DE META-HEURÍSTICAS NO ESCALONAMENTO DE
MOTORISTAS PARA O TRANSPORTE DE MADEIRA**

JERÔNIMO MONTEIRO – ES
MARÇO – 2012

MARCOS FÁVERO COSTA

**APLICAÇÃO DE META-HEURÍSTICAS NO ESCALONAMENTO DE
MOTORISTAS PARA O TRANSPORTE DE MADEIRA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de concentração Ciências Florestais.

Orientador: Prof. Dr. Nilton Cesar Fiedler
Coorientador: Prof. Dr. Geraldo Regis Mauri

JERÔNIMO MONTEIRO – ES

MARÇO – 2012

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial de Ciências Agrárias, Universidade Federal do Espírito Santo, ES, Brasil)

Costa, Marcos Fávero, 1987-
837a (Aplicação de meta-heurísticas no escalonamento de motoristas para o
transporte florestal / Marcos Fávero Costa. – 2012.
61 f. : il.

Orientador: Nilton Cesar Fiedler.
Coorientador: Geraldo Regis Mauri.
Dissertação (Mestrado em Ciências Florestais) – Universidade Federal
do Espírito Santo, Centro de Ciências Agrárias.

1. Florestas – Transporte. 2. Programação heurística. 3. Motorista de
caminhão. 4. Logística. 5. Economia florestal. I. Fiedler, Nilton Cesar. II.
Mauri, Geraldo Regis. III. Universidade Federal do Espírito Santo. Centro de
Ciências Agrárias. IV. Título.

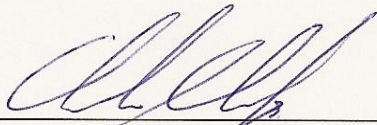
CDU: 630

**APLICAÇÃO DE META-HEURÍSTICAS NO ESCALONAMENTO DE
MOTORISTAS PARA O TRANSPORTE DE MADEIRA**

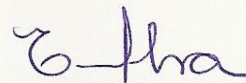
Marcos Fávero Costa

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de Concentração Ciências Florestais.

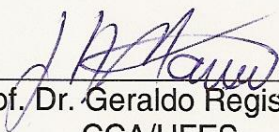
Aprovada em 01 de Março de 2012.



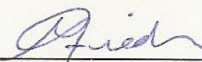
Prof. Dr. Eduardo da Silva Lopes
UNICENTRO-PR
Membro Externo



Prof. Dr. Elizabeth Neire da Silva
Oliveira de Paula
CCA/UFES
Membro Interno



Prof. Dr. Geraldo Regis Mauri
CCA/UFES
Coorientador



Prof. Dr. Nilton Cesar Fiedler
CCA/UFES
Orientador

*Dedico este trabalho aos meus avós,
pois foram eles que me deram o meu
maior tesouro, minha família.*

AGRADECIMENTOS

Agradeço aos meus pais Sirlei e Jânio e à minha irmã Maísa pelos ensinamentos, carinho, dedicação, confiança e toda força e apoio que recebi durante toda a vida. Aos tios e primos das famílias Fávero e Costa, pois a companhia de vocês é o que me motiva a viver.

À Universidade Federal do Espírito Santo e ao Programa de Pós-Graduação em Ciências Florestais, pela oportunidade concedida. Ao laboratório de Colheita Florestal, Ergonomia e Logística (LABCELF – UFES) pelo espaço físico e equipamentos cedidos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de Mestrado que foi de suma importância para realização do curso.

À Celulose Nipo-brasileira S.A., pela oportunidade no desenvolvimento da dissertação.

Agradeço a todos os professores com que tive contato e em especial ao Prof. Nilton pelos ensinamentos transmitidos, pela ajuda nos momentos difíceis e por depositar sua confiança em mim, e também ao Prof. Geraldo pela dedicação, incentivo e pelas proveitosas horas de conversa. Aos Professores Eduardo da Silva Lopes e Elizabeth Neire da Silva Oliveira de Paula pelo auxílio e por aceitarem o convite de participar da banca examinadora.

Aos alunos do Curso de Ciência da Computação (CCA-UFES) André, Gélinton, Rômulo, Túlio e Vinícius Alopras pela parceria firmada no desenvolvimento dos métodos heurísticos.

E por fim, mas, não menos importante, aos amigos Elter, Léo Peroni, Ragner, Lulis, Lila, PH, Jefim, Saras Guerra, Bia, Cabecinha, Flávim, Tonetto, Guilherme, André Perito, Pelosso, Dominique, Léo Nazário, Boi, aos colegas de república Murilim e Hassanga e aos membros da Equipe (Albino, Bunitim, o Calouro do Canário, Edgar, Madeira, Mortinho, R'Alessi e Carioca), o meu muito obrigado por ter vocês como verdadeiros amigos.

LISTA DE TABELAS

Tabela 1.	Distância (km) entre os trechos do ciclo de viagem dos veículos de transporte.	32
Tabela 2.	Escala mensal de trabalho.	34
Tabela 3.	Pontos de trocas de turnos.	35
Tabela 4.	Codificação atribuída aos locais do ciclo de viagem.	38
Tabela 5.	Exemplo de viagens realizadas por um motorista.	39
Tabela 6.	Cenários, pesos e objetivos	42
Tabela 7.	Resultados das meta-heurísticas para o Cenário 1	49
Tabela 8.	Resultados das meta-heurísticas para o Cenário 2	49
Tabela 9.	Resultados das meta-heurísticas para o Cenário 3	50
Tabela 10.	Resultados das meta-heurísticas para o Cenário 4	50
Tabela 11.	Resultados das meta-heurísticas para o Cenário 5	51
Tabela 12.	Melhores soluções geradas para o Cenário 1	51
Tabela 13.	Melhores soluções geradas para o Cenário 2.	52
Tabela 14.	Melhores soluções geradas para o Cenário 3.	53
Tabela 15.	Melhores soluções geradas para o Cenário 4.	53
Tabela 16.	Melhores soluções geradas para o Cenário 5.	54
Tabela 17.	Comparação entre valores observados e resultado da pior meta-heurística	56
Tabela 18.	Comparação entre valores observados e resultado da melhor meta-heurística	56
Tabela 19.	Exemplo de escala de serviço.	57

LISTA DE FIGURAS

Figura 1. Localização Cenibra S.A.....	27
Figura 2. Localização das áreas florestais da empresa no leste de Minas Gerais.....	28
Figura 3. Combinações de veículos de carga utilizados no transporte.	30
Figura 4. Fluxograma ciclo operacional.....	31
Figura 5. Escala de trabalho da frota e dos motoristas.	34
Figura 6. Formato de entrada de dados.	40
Figura 7. Algoritmo Genético implementado.	43
Figura 8. Algoritmo Memético implementado.	44
Figura 9. <i>Clustering Search</i> implementado.	45
Figura 10. GRASP implementado.	46
Figura 11. <i>Simulated Annealing</i> implementado.....	47
Figura 12. Comparação entre os melhores resultados no Cenário 5.	55

SUMÁRIO

RESUMO	IX
ABSTRACT	X
1. INTRODUÇÃO.....	11
1.1. OBJETIVOS.....	12
2. REVISÃO BIBLIOGRÁFICA.....	13
2.1. O SETOR FLORESTAL BRASILEIRO	13
2.2. TRANSPORTE DE MADEIRA NO BRASIL	14
2.3. ESTUDO DE TEMPOS E MOVIMENTOS	15
2.4. PESQUISA QUALITATIVA E ETNOGRÁFICA	16
2.5. PESQUISA OPERACIONAL.....	17
2.5.1. Meta-heurísticas	20
2.5.1.1. Algoritmo Genético.....	21
2.5.1.2. Algoritmo Memético.....	22
2.5.1.3. <i>Clustering Search</i>	23
2.5.1.4. <i>Greedy Randomized Adaptive Search</i>	23
2.5.1.5. <i>Simulated Annealing</i>	24
2.5.2. Métodos de otimização aplicados à logística florestal	25
3. MATERIAIS E MÉTODOS	27
3.1. LOCAL DE ESTUDO	27
3.2. DESCRIÇÃO DO MODELO DE TRANSPORTE DE MADEIRA UTILIZADO.....	29
3.2.1. Ciclo Operacional	29
3.2.2. Restrições Operacionais.....	33
3.2.3. Escala Diária e Mensal	33
3.2.4. Trocas de Turno.....	34
3.2.4.6. Trocas de turno no pátio.....	35
3.2.4.7. Trocas de turno no ponto de apoio.....	36
3.2.4.8. Trocas de turno em Belo Oriente	36
3.2.4.9. Trocas de turno em Açucena	36
3.2.4.10. Trocas de turno em Sapucaia	37
3.3. COLETA DE DADOS	37
3.4. CONSTRUÇÃO DO MODELO.....	40
3.5. RESOLUÇÃO DO MODELO.....	42
4. RESULTADOS E DISCUSSÃO.....	48
4.1. DIAGNÓSTICO DA ATUAL SITUAÇÃO DO TRANSPORTE DE MADEIRA NA EMPRESA.....	48
4.2. COMPARAÇÃO ENTRE AS META-HEURÍSTICAS USADAS NA OTIMIZAÇÃO DO ESCALONAMENTO DE MOTORISTAS.....	48
4.3. COMPARAÇÃO ENTRE AS META-HEURÍSTICAS E A SITUAÇÃO ATUAL DA EMPRESA	54
4.4. NOVA ESCALA DE SERVIÇOS	56
5. CONCLUSÕES.....	58
6. REFERÊNCIAS	59

RESUMO

COSTA, Marcos Fávero. **Aplicação de meta-heurísticas no escalonamento de motoristas para o transporte de madeira.** 2012. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Alegre-ES. Orientador: Prof. Dr. Nilton Cesar Fiedler. Coorientador: Prof. Dr. Geraldo Regis Mauri.

O transporte de cargas do setor florestal brasileiro é realizado em sua maior parte pelo modal rodoviário. Sua complexidade exhibe a importância de diagnosticar o desenvolvimento da atividade para que se possa, por meio da pesquisa operacional, empregar de forma mais eficiente seus recursos disponíveis sem que haja perda de produtividade. Atualmente, o problema de escalonamento de motoristas é considerado um dos principais entraves à otimização em empresas de transporte, pois apresenta uma grande quantidade de restrições físicas e técnicas. Esta pesquisa teve como objetivo solucionar um problema real de escalonamento de motoristas no transporte de madeira de uma empresa florestal por meio de cinco meta-heurísticas (Algoritmo Genético – AG, Algoritmo Memético – AM, *Clustering Search* – CS, *Greedy Randomized Adaptive Search* – GRASP e *Simulated Annealing* – SA), comparar os métodos entre si e entre a situação corrente na empresa, e propor uma nova escala de serviços. Para validação da abordagem proposta, foi utilizada uma entrada de dados gerada a partir da pesquisa qualitativa e de estudos de tempos e movimentos. Os resultados indicam que todos os métodos foram eficientes para resolver o problema sobressaindo-se o CS como melhor, seguido do SA, GRASP, AM e AG. O CS conseguiu atender aos objetivos com uma redução em 1/3 do quadro de 150 motoristas além de eliminar médias diárias de horas extras e excedentes que eram de 01h03min e 00h51min, respectivamente.

Palavras-chave: transporte florestal, meta-heurísticas, escalonamento de motoristas, logística de transporte, produção florestal.

ABSTRACT

COSTA, Marcos Fávero. **Application of metaheuristics in drivers scheduling for the transport timber**. 2012. Dissertation (Master in Forest Science) – Universidade Federal do Espírito Santo, Alegre-ES. Adviser: Prof. Dr. Nilton Cesar Fiedler. Co-adviser: Prof. Dr. Geraldo Regis Mauri.

The cargo transportation in Brazilian forest area is carried out mostly by road. Their complexity shows the importance of diagnosing the development of the activity so that we can, means operational research, more efficiently employ their resources without losing productivity. Currently, the driver scheduling problem is considered a major constraint for optimizing of transportation companies, because it has a lot of physical and technical restriction. This research aimed to solve a real problem of driver scheduling for the wood transportation from a forest company by using five metaheuristics (Genetic Algorithm – AG, Memetic Algorithm – AM, Clustering Search – CS, Greedy Randomized Adaptive Search – GRASP, and Simulated Annealing – SA), compare the methods among themselves and between the company's actual situation and propose a new scale of services. To validate the proposed approach, we used a data input generated from the qualitative research and studies time and movement. The results indicate that all methods were effective to solve the problem standing out as the best CS, followed by the SA, GRASP, AM and AG. The CS was able to meet the goals with a reduction of one third of the frame of 150 drivers and eliminates daily averages of overtime and surpluses which were 01h03min and 00h51min, respectively.

Keywords: Forest transport, metaheuristics, driver scheduling, logistics, production forest.

1. INTRODUÇÃO

O transporte é um dos fatores de composição do custo logístico de maior valor, e nas nações desenvolvidas, somente os fretes costumam consumir aproximadamente 60% do gasto logístico total e entre 9% a 10% do produto nacional bruto, remetendo a buscar sempre uma eficiência e qualidade em todas as fases do processo (RODRIGUES, 2007).

Considerando o histórico e a tendência nacional, o transporte florestal em sua maioria é realizado pelo modal rodoviário, devido a diversos fatores como extensa malha viária, oferta de diferentes tipos de Combinações de Veículos de Cargas (CVC) e baixo valor de instalação quando comparado a outros modais existentes (MACHADO et al., 2009).

As empresas de maior porte, normalmente, possuem várias unidades de produção de madeira em regiões rurais, nem sempre próximas das indústrias de transformação. Além disso, convivem com diversas restrições ligadas às condições de estradas, comunidades, legislação, pessoal operacional, carregamento e descarregamento, condições meteorológicas, tipos de CVC utilizados e prestadores de serviços. Devido a esse extenso número de variáveis, as empresas florestais têm dificuldades em planejar o transporte de matérias-primas das áreas de produção para as indústrias de uma forma contínua e programada.

O uso de técnicas científicas como a pesquisa operacional e o estudo de tempos e movimentos serve de ferramentas para esse planejamento. Com a otimização das atividades que fazem parte do ciclo do transporte consegue-se aplicar de uma maneira mais eficiente os recursos disponíveis, sem deixar de atender as restrições e os objetivos almejados.

No transporte o motorista é uma das principais peças e conseguindo atribuir uma escala de serviços durante um determinado período de tempo a cada um deles aliada aos objetivos da empresa e restrições trabalhistas as companhias têm capacidade de se tornarem mais competitivas no mercado.

Embora o problema de criação de escalas de motoristas tenha seu estudo e sua aplicação bastante difundidos em países desenvolvidos, o mesmo não ocorre em países “em desenvolvimento”. Suas técnicas de resolução ainda

são poucas, ou quase que raramente aplicadas em países como o Brasil (MAURI, 2005). Esse fato ocorre, em geral, devido às condições em que atuam as empresas de transporte no país, principalmente, com relação às restrições operacionais impostas a elas e também ao que diz respeito ao cumprimento de legislações trabalhistas. Outro fato importante é por se tratar de um problema NP-difícil (Karp, 1972) devido à quantidade de variáveis e de restrições envolvidas o que tornaria inviável sua resolução por métodos exatos.

O diagnóstico aqui apresentado também é uma contribuição para a disseminação de técnicas de otimização combinatória dentro do setor florestal. Além disso, oferece subsídios para que as empresas possam manter-se competitivas, aprimorando cada vez mais seus processos produtivos, tentando manter a qualidade de seus produtos e/ou serviços. Conseqüentemente, reduz seus custos, utilizando, de maneira eficiente, seus recursos materiais e humanos mantendo-se lucrativas, sem, no entanto, comprometer a qualidade dos serviços oferecidos.

1.1. OBJETIVOS

Esta pesquisa teve por objetivo geral aplicar técnicas de meta-heurísticas no escalonamento de motoristas no transporte de madeira em uma empresa florestal situada no Vale do Rio Doce – MG.

Especificamente, objetivou-se:

1. Diagnosticar a situação atual do transporte de madeira na empresa florestal;
2. Comparar cinco diferentes meta-heurísticas usadas na otimização do escalonamento de motoristas;
3. Comparar os resultados das meta-heurísticas com a situação atual da empresa, e;
4. Propor uma escala de serviços otimizada que facilite a redução dos custos operacionais.

2. REVISÃO BIBLIOGRÁFICA

2.1. O SETOR FLORESTAL BRASILEIRO

Após a aprovação da lei nº 5.106, de setembro de 1966, que dispõe sobre os incentivos fiscais concedidos a empreendimentos florestais, permitindo às empresas abaterem até 50% do valor do imposto de renda devido, o setor florestal começou a se destacar no Brasil. O crescimento da área reflorestada no país situou-se na faixa de 100 a 250 mil hectares anuais entre 1968 a 1973, elevando-se para 450 mil hectares anuais entre 1974 e 1982 (SOARES et al., 2008).

Mesmo com o fim dos incentivos, em 1988, o setor continuou se desenvolvendo no país, com a chegada de grandes empresas de base florestal que se dedicaram a ampliar sua área reflorestada utilizando recursos próprios ou oriundos de empréstimos de longo prazo em bancos de fomento federais ou estaduais, ou incentivando o reflorestamento em pequenos e médios imóveis rurais (ANTONANGELO; BACHA, 1998; LEÃO, 2000).

Segundo a Associação Brasileira de Produtores de Floresta Plantada – ABRAF (2011), o Brasil totalizou uma área ocupada por florestas plantadas de 6.510.693 hectares, sendo 73% correspondente à área de plantio do gênero *Eucalyptus* e 27% a plantios do gênero *Pinus*. O crescimento da área de plantios em 2010 foi de 3,2% em relação ao ano anterior, um crescimento modesto já que no período de 2005-2009 esse percentual foi de 4,5% a.a. A não efetuação dos investimentos previstos para o ano de 2010, como tentativa de recuperação da pré-crise financeira aliada às incertezas relativas ao mercado internacional de vários produtos da cadeia de base florestal fizeram com que as empresas do setor poupassem investimentos em novas unidades industriais, prorrogando também a expansão dos plantios (ABRAF, 2011). Outro empecilho aos investimentos foi o parecer AGU LA nº 1/2010, que impede que empresas controladas pelo capital estrangeiro adquiram imóveis rurais acima de 50 módulos fiscais.

Também segundo a ABRAF (2011) para a economia brasileira e para a sociedade em geral, o setor florestal contribui com uma parcela importante na

geração de produtos, tributos, divisas, empregos e renda. Estima-se que o setor florestal manteve, aproximadamente, 4,7 milhões de empregos, incluindo empregos diretos (640,4 mil), indiretos (1,45 milhões) e empregos resultantes do efeito-renda (2,60 milhões). Sua participação representa em, aproximadamente, 5% do produto interno bruto (PIB).

2.2. TRANSPORTE DE MADEIRA NO BRASIL

O transporte de madeira é uma das operações mais importantes na linha produtiva do setor florestal, principalmente, pelo elevado custo e exigência de um planejamento que requer decisões racionais para que as atividades se mantenham flexíveis e em ordem pré-estabelecida, evitando gargalos no decorrer da cadeia (BERGER et al., 2003).

Para atender a demanda das indústrias e serem competitivas no mercado, as empresas florestais demandam, em suas operações, versatilidade, confiabilidade, economia e bom desempenho (TIBURCIO, 2008).

No Brasil, o transporte de madeira pode ser feito por diferentes tipos de veículos, dependendo da distância, do volume a ser transportado, das condições locais, da capacidade de carga do veículo e dos tipos de equipamentos utilizados para fazer o carregamento e descarregamento (MACHADO et al., 2009).

Os veículos empregados no transporte florestal rodoviário podem ser qualificados de acordo com a capacidade de carga como (MACHADO et al., 2009):

1. Leve: veículo simples, com capacidade de carga de até 10 t;
2. Médio: veículo simples, com capacidade de carga entre 10 e 20 t;
3. Semipesado: veículo simples, articulado ou conjugado, com capacidade de carga entre 20 e 30 t;
4. Pesado: veículo articulado ou conjugado, com capacidade de carga entre 30 e 40 t, e;
5. Extrapesado: veículos do tipo rodotrem, treminhão, bitrem e tritrem com capacidades de carga acima de 40 t.

Os autores destacam como fatores que influenciam o transporte de cargas pelo modal rodoviário os tipos de veículo, a distância de transporte, o valor unitário do frete, as condições em que se encontram a malha rodoviária, o tempo de espera no carregamento e descarregamento, a capacidade de carga em volume que transportado pelo veículo, às condições locais e regionais e os tipos de equipamentos de carregamento e descarregamento.

2.3. ESTUDO DE TEMPOS E MOVIMENTOS

Para Barnes (1977), assim como os demais custos na operação de uma empresa, a mão-de-obra necessita ser considerada e trabalhada objetivando aumentar o lucro sob a venda do produto final. Todas as operações devem ser analisadas de forma a encontrar o método mais fácil e melhor para cada processo.

O estudo de tempos e movimentos é uma técnica utilizada para o planejamento e organização do trabalho, com a finalidade de: configurar um local de trabalho adequado assim como os meios de produção; definir a técnica e, ou, o método para efetuar as operações; organizar a sequência de execução do trabalho e; controlar a produtividade (SIMÕES, 2008).

Esse estudo estabelece programações e planeja o trabalho, determina os custos-padrão e auxilia no preparo de orçamentos; estima o custo de um produto antes do início da fabricação. Esta informação é de valor no preparo de propostas para concorrência e na determinação do preço de venda do produto. O estudo de tempos tem por finalidade, também, determinar a eficiência de máquinas, o número de máquinas que uma pessoa pode operar o número de homens necessários ao funcionamento de um grupo, e como um auxílio ao balanceamento de linhas de montagem e de trabalho controlado por transportadores; determina tempos-padrão a serem usados como base para o pagamento de incentivo à mão-de-obra direta e indireta, tais como movimentadores de materiais e preparadores de produção e, por fim, é um método utilizado para determinar tempos padrão a serem usados como base do controle de custo da mão-de-obra (BARNES, 1977).

Para execução dos estudos de tempos, necessita-se basicamente de um aparelho medidor dos tempos consumidos e de equipamentos para auxílio dessas medições (LOPES, 2010).

Barnes (1977) diz que a partir da padronização da operação que se deseja fazer um estudo de tempos, pode-se iniciar o processo de cronometragem. Esta medida deve ser considerada a fim de poupar tempo e dinheiro em um estudo que possa vir a se tornar desatualizado e, portanto, inútil. Lopes (2010) define três métodos para medição dos tempos e movimentos:

1. Método de Tempo Contínuo: a medição dos tempos ocorre sem detenção do cronômetro, de forma contínua. O técnico faz a leitura do cronômetro cada vez que acontece um ponto de medição e anota o tempo que indica o cronômetro nesse momento, sem detê-lo, junto ao nome da atividade recém-terminada. O tempo requerido por cada trabalho parcial é calculado durante a avaliação por sua subtração entre a hora em que terminou a atividade parcial em questão e a hora em que se iniciou;
2. Método de tempo individual: O tempo de cada elemento do ciclo operacional nesse método é obtido diretamente. Após cada medição os ponteiros voltam à posição zero, não sendo necessário fazer subtrações como no método anterior, e;
3. Método de multimomento: utilizam-se cronômetros que giram continuamente. Neste caso, não se medem os tempos do ciclo e sim sua frequência em intervalos de tempos fixos, ou seja, cada vez que o ponteiro passa pelo intervalo fixado é anotada a atividade que ocorre nesse momento.

2.4. PESQUISA QUALITATIVA E ETNOGRÁFICA

A expressão “pesquisa qualitativa” assume diferentes significados no campo das ciências sociais. Compreende um conjunto de técnicas interpretativas que visam a descrever e decodificar os componentes de um sistema complexo de significados. Tem por objetivo traduzir e expressar o

sentido dos fenômenos do mundo social; trata-se de reduzir a distância entre indicador e indicado, entre contexto e ação (MAANEN, 1979). Em sua maioria, os estudos qualitativos são feitos no local de origem dos dados; não impedem o pesquisador de empregar a lógica do empirismo científico (adequada para fenômenos claramente definidos), mas partem da suposição de que seja mais apropriado empregar a perspectiva fenomenológica, quando se trata de fenômenos singulares e dotados de certo grau ambiguidade.

A etnografia é definida como um método para pesquisa que incorpora o exame de dados empíricos escolhidos metodicamente para a análise, originários de conjunturas estabelecidas e de uma variedade de fontes, ainda que o enfoque necessite ser precário em grandeza, avaliando alguns grupos de pessoas (HAMMERSLEY, 1994).

Barton e Hamilton (1998) delinearam quatro aspectos essenciais da pesquisa etnográfica: (1) utilização de dados reais e situados; (2) foco no processo social como um todo; (3) utilização de método múltiplo e (4) análise interpretativa.

A coleta de dados etnográficos e sua fixação em textos passíveis de análise seguem uma estrutura metodológica estabelecida, que conta com variados métodos a serem utilizados de acordo com os objetivos de cada pesquisa. Os métodos clássicos para coleta de dados de campo são a observação e a entrevista etnográfica (CRABTREE e MILLER, 1992).

2.5. PESQUISA OPERACIONAL

A ciência da pesquisa operacional é aplicada na resolução de problemas, inclusive os empresariais, utilizando modelos matemáticos com a assistência de computadores. Os processos de tomada de decisão muitas vezes envolvem elementos objetivos (racionais) e subjetivos (enquadramento organizacional). Ambos são contemplados nos modelos de pesquisa operacional para a solução dos problemas. Sua função de encontrar soluções ótimas tem uso nas mais diversas atividades, inclusive nas de alocação de recursos, sejam eles financeiros, materiais, patrimoniais, humanos ou tecnológicos (LACHTERMACHER, 2006).

A logística passou a utilizar a pesquisa operacional como método para a solução de seus problemas a partir da Segunda Guerra Mundial. A disciplina criada para o ambiente militar transcendeu suas fronteiras iniciais e encontrou abrigo tanto na comunidade acadêmica como empresarial no ramo da administração (ANDRADE, 1998).

Dentre as vantagens da utilização da pesquisa operacional na determinação da melhor alocação de recursos limitados ou escassos está a possibilidade da realização de simulações de situações reais, antecipando o conhecimento dos potenciais resultados e suas probabilidades de ocorrência. Os métodos, portanto, permitem a avaliação de alternativas com a otimização das atividades e de recursos (MÉLLO et al., 2009).

Algumas fases são observadas na solução de problemas com pesquisa operacional. As mais importantes, segundo Goldberg e Luna (2005), são descritas a seguir:

1. Definição do problema: são definidos os objetivos, as alternativas de decisão, os limites e as restrições das variáveis;
2. Construção do modelo: são apresentadas as características mais importantes do problema abordado. O conhecimento obtido é representado por meio de imagens intelectuais sobre o que é mais relevante da porção da realidade em análise;
3. Solução do modelo: o método apresenta as saídas ótimas para as entradas de informações do modelo em questão;
4. Validação do modelo: o modelo é válido se tiver soluções de previsão apropriadas para a realidade estudada e se forem úteis para a tomada de decisão;
5. Implementação da solução: nesse momento são transferidos para a realidade os resultados provenientes das simulações ou das otimizações, e;
6. Avaliação final: observação dos resultados práticos do que foi sugerido na solução através dos modelos.

É importante destacar que os modelos traduzem apenas uma porção da situação real e que, pela sua simplificação, podem mostrar soluções que são boas para um segmento da empresa ao passo que são inadequadas para

a empresa de maneira geral. A Teoria Geral dos Sistemas recomenda que as partes sejam interdependentes, e que deve haver tratamento complexo para realidade complexa (MAXIMIANO, 2002).

Por apresentar características multidisciplinares, a pesquisa operacional é uma matéria científica, com abrangências horizontais, que permitem o seu uso em quase todas as situações da vida, principalmente naquelas em que devemos decidir determinadas características de um sistema de forma a dele extrair o maior número possível de benefícios, por exemplo, como uma tomada de preços de insumos visando a maximização dos lucros, ou a escolha de uma rota que minimize as distâncias percorridas pelos veículos (LUCAS, 2002).

Lucas (2002) diz ainda que a matemática permite transformar tais situações do mundo real em funções, e assim pode-se encontrar quais os melhores valores para maximizar ou minimizar seus objetivos, e a otimização combinatória tem como principal função encontrar a melhor combinação dos recursos disponíveis e suas características para otimizar seu uso.

Problemas de otimização combinatória são comuns em diversas áreas e estão presentes em grande parte das atividades cotidianas como nos serviços de transporte e entregas (MAURI, 2008).

Para Ronen (1988), um dos fatores que certamente contribui muito para a operacionalização do sistema de forma integrada e planejada é ligado à equipe de funcionários do transporte. O autor ainda afirma que os motoristas dos veículos de transporte devem ter um treinamento adequado, conhecer as rotas, os veículos, os fatores influentes no transporte e terem suas escalas de trabalho definidas corretamente.

Deve-se considerar que o motorista que opera tais veículos é um ser humano, e assim devem ser respeitadas suas necessidades e seus direitos para que o mesmo possa trabalhar de forma mais harmônica, tornando seu serviço mais eficiente.

A determinação de modelos matemáticos para esses problemas é uma importante estratégia não só para formalizá-los como também para resolvê-los. Meta-heurísticas frequentemente são exploradas quando não se conhece um modelo matemático para um problema, ou quando se percebe que “a solução é

mais complicada do que parece”. Apesar de não garantir a obtenção das soluções ótimas para os problemas, essa técnica geralmente apresenta boas soluções em pequenos intervalos de tempo computacional (MAURI, 2008).

2.5.1. Meta-heurísticas

Uma meta-heurística pode ser considerada como um método baseado em diferentes conceitos que podem ser utilizados para resolver de forma genérica um extenso conjunto de diferentes problemas de otimização combinatória. Em outras palavras, uma meta-heurística pode ser vista como um método algorítmico genérico, que pode ser aplicado a diferentes problemas de otimização (MNWS, 2011).

Embora a solução encontrada por uma meta-heurística não seja necessariamente a melhor possível, sua importância é que elas fornecem ideias que podem ser aplicadas aos problemas de otimização para os quais não são conhecidos algoritmos específicos eficientes (SUCUPIRA, 2004).

Melían et al. (2003) sugere uma possível classificação de acordo com a abordagem utilizada:

1. Meta-heurísticas construtivas: definem de forma meticulosa o valor de cada componente da solução, como exemplo, GRASP;
2. Técnicas de relaxação: simplificam o problema criando um problema relaxado e utilizam a solução encontrada como guia para o problema original, como exemplo, Relaxação Lagrangiana;
3. Meta-heurísticas de busca por entornos: percorrem o espaço de busca levando em conta, fundamentalmente, a “vizinhança” da solução corrente, definida como o conjunto de soluções que podem ser obtidas a partir da aplicação de algum operador à solução corrente, como exemplo, SA, e;
4. Meta-heurísticas evolutivas: lidam com uma população de soluções, que evolui, principalmente, por meio da interação entre seus elementos, como exemplo, AG e AM.

Além dessa classificação de Melían et al. (2003), uma estratégia comum atualmente são as meta-heurísticas híbridas, que são combinações

entre diferentes meta-heurísticas, entre meta-heurísticas e métodos exatos, meta-heurísticas com algoritmos específicos para o problema em foco e meta-heurísticas com outras técnicas de pesquisa operacional e/ou Inteligência Artificial. O uso de meta-heurísticas híbridas pode proporcionar um comportamento mais eficiente e uma maior flexibilidade dos problemas reais de larga escala, além de obter sistemas de melhor desempenho que explorem e unam as vantagens das estratégias puras aplicadas individualmente (CHAVES, 2007a).

Raidl (2006) classifica as meta-heurísticas híbridas da seguinte maneira:

1. Nível de Híbridação: quando é mantida a identidade individual dos algoritmos originais que cooperam por meio de uma interface bem definida ela é chamada de *High-level*. Caso os algoritmos dependam fortemente um do outro, é caracterizada como *Low-level*;
2. Ordem de Execução: dita Sequencial quando um algoritmo é executado depois de outro e a informação é passada de forma unidirecional; Intercalado quando a cada iteração de um algoritmo, o outro é executado; e Paralelo se os algoritmos são executados paralelamente e as informações são passadas em qualquer direção;
3. Estratégia de Controle: se um algoritmo é considerado um subordinado, ou seja, componente embutido de outro algoritmo, ele é classificado como Integrado; e Colaborado quando algoritmos trocam informação, mas não são partes um do outro.

A seguir são apresentadas as meta-heurísticas que foram utilizadas para resolução do problema de escalonamento de motoristas considerado neste trabalho.

2.5.1.1. Algoritmo Genético

Algoritmo Genético (AG), proposto por Holland (1975), é considerado um método que trabalha com buscas paralelas e randômicas direcionadas, inspirado na genética e no princípio Darwiniano da evolução das espécies (GOLDBERG, 1989) no qual, dada certa população, os indivíduos de melhores

características genéticas possuem maiores chances de se adaptarem ao meio ambiente e, assim, gerar descendentes, enquanto indivíduos piores são menos aptos e tendem a desaparecerem.

Seu objetivo é criar um conjunto de possíveis soluções para o problema, denominada população, na qual cada solução é considerada um indivíduo. Cada indivíduo recebe uma classificação refletindo sua capacidade de adaptação. É feita uma seleção, considerando a aptidão dos indivíduos, que por sua vez podem sofrer modificações (cruzamento ou *crossover* e mutações) gerando descendentes para a próxima geração. A esse processo é dado o nome de reprodução, e ele é repetido até que um critério de parada seja satisfeito (LUCAS, 2002).

Depois de realizada as etapas de cruzamento e mutação, os melhores indivíduos, “filhos” gerados e/ou pais, formam uma nova população e os demais são descartados. O algoritmo é finalizado por um teste que dá fim ao processo de evolução, como um número de gerações, por exemplo.

2.5.1.2. Algoritmo Memético

Moscato (1989) propôs um novo algoritmo, baseado na teoria dos Algoritmos Evolutivos, chamado de Algoritmo Memético (AM), uma junção do AG com operadores de busca local.

O termo “meme” está relacionado à evolução cultural de um indivíduo, e não às características hereditárias. Dawkins (1976) o descreve como uma “unidade de evolução” que compete com seus alelos (memes rivais) por recursos (tempo e espaço) nas “máquinas de sobrevivência” (cérebro).

Todas as etapas dos AG, como os operadores de seleção, recombinação e mutação estão presentes nos AM. A diferenciação entre essas duas classes de algoritmos ocorre pela inclusão de uma etapa de otimização dos indivíduos através da adição de operadores de busca local independentes, que particularizam o aprendizado para cada indivíduo. Quando o meme é transmitido, ele será adaptado pela entidade que o recebe, com base no seu conhecimento e para melhor atender às suas necessidades (COELHO, 2006).

2.5.1.3. *Clustering Search*

O *Clustering Search* (CS) é uma evolução da meta-heurística proposta por Oliveira (2004) chamada de *Evolutionary Clustering Search* (busca evolutiva de agrupamentos).

De acordo com Chaves (2009), durante o processo de busca realizado por um algoritmo, há uma maior concentração de indivíduos em regiões nas quais estão os melhores avaliados. Então, o CS procura dividir o espaço de busca e localizar regiões promissoras por meio do enquadramento dessas em *clusters*, que possuem três atributos: c_i (centro do *cluster i*), v_i (quantidade de soluções agrupadas no *cluster i*) indica que *cluster* se torna promissor quando o volume atingir certo limitante e r_i (índice de ineficácia da busca no *cluster i*) que é uma variável de controle para identificar se a “busca local” está ou não melhorando o centro do *cluster i*. Depois de encontrada essas regiões promissoras, é intensificada a busca por ótimos locais.

Esse método possui três componentes principais: uma meta-heurística para gerar soluções que "alimentam" os *clusters*, um processo de agrupamento que agrupa as soluções similares em um *cluster* e um método de busca local que faz uma busca local em *clusters* com volume de soluções maior ou igual a um parâmetro pré-estabelecido.

2.5.1.4. *Greedy Randomized Adaptive Search*

O *Greedy Randomized Adaptive Search Procedure* (GRASP) ou o Procedimento de Busca Adaptativa Gulosa e Randômica é um processo iterativo ou de vários inícios desenvolvido por Feo e Resende (1989).

É um método de otimização que se divide em duas fases: a fase de construção e a fase de busca local. A primeira consiste em construir uma solução viável combinando gulosidade e aleatoriedade. A cada iteração, a escolha do próximo elemento a ser adicionado é determinada pela ordenação de todos os elementos candidatos, em uma lista restrita de candidatos ou

Resticted Candidate List (RCL). A ordenação é feita mediante a avaliação de cada elemento conforme a função gulosa, que seleciona em sequência o elemento que minimiza o custo de incremento da solução parcial, atualizando o benefício a outros elementos a cada iteração. Já a fase de busca local gera alguma melhoria na solução corrente, através de uma busca local nas regiões vizinhas para encontrar o ótimo local. As soluções geradas na fase de construção não são necessariamente ótimas, e a eficácia da busca local depende da estrutura de vizinhança, da estratégia de busca, da rápida avaliação dos vizinhos e também do próprio procedimento de construção.

2.5.1.5. *Simulated Annealing*

O *Simulated Annealing (SA)* é um método de busca local que aceita movimentos de piora para escapar de ótimos locais. Ele foi proposto originalmente por Kirkpatrick et al. (1983) e se fundamenta em uma analogia com a termodinâmica, ao simular o processo de “recozimento” de metais. Seu princípio sugere que em um resfriamento rápido conduz a produtos metaestáveis, de maior energia interna enquanto que um resfriamento lento conduz produtos mais estáveis, estruturalmente fortes e de menor energia. Durante o processo de recozimento, o material passa por vários estados possíveis e num período de tempo longo esse material passará por todos os seus estados acessíveis.

O algoritmo de busca é empregado numa sequência de temperaturas decrescentes para gerar soluções de um problema de otimização. Ele começa com um valor T elevado e a cada T geram-se soluções até que o equilíbrio àquela temperatura seja alcançado. Então, a temperatura é rebaixada e o processo segue até o congelamento, ou seja, chega-se ao ponto onde não se obtém mais melhoras. A sequência de temperaturas empregadas assim como o número de iterações a cada temperatura constitui uma prescrição de recozimento, que deve ser definida empiricamente (CHAVES, 2007b).

A cada iteração do método, é gerado aleatoriamente um novo estado a partir do estado corrente e, se esse novo estado for de energia menor, ele passa a ser o estado corrente (MAURI, 2011).

Este procedimento é repetido até se atingir o equilíbrio térmico. Quanto maior a temperatura maior será a probabilidade de aceitação, pois cada estado possui a mesma chance de ser o estado corrente. Já a baixas temperaturas, somente estados com baixa energia, ou seja, as boas soluções possuem uma maior probabilidade de ser o estado corrente. Quando o equilíbrio térmico em uma dada temperatura é atingido, esta é diminuída e o processo se repete. O método chega ao fim quando a temperatura se aproxima de zero e nenhuma solução de piora é mais aceita, evidenciando o encontro de um ótimo local (MAURI, 2011).

2.5.2. Métodos de otimização aplicados à logística florestal

Paredes e Sessions (1988) elaboraram procedimentos que aumentam a eficiência dos sistemas de transporte florestal e que proporcionam maneiras alternativas de transporte de madeira e escolhas para a localização dos pátios para a transferência de madeira.

Seixas e Widmer (1993) desenvolveram um método para auxiliar a racionalização do dimensionamento da frota responsável pelo transporte principal de madeira através da programação linear não-inteira.

Arce (1997) desenvolveu um sistema de programação de transporte principal de multiprodutos florestais com o objetivo de minimizar os custos de transportes pagos na atualidade. O sistema é constituído de dois módulos onde o primeiro é o responsável pela minimização global dos custos de transporte principal enquanto que o segundo módulo é responsável pela programação no tempo de viagens da frota.

Já Lacowicz et al. (2002) estudaram a minimização de custos do transporte rodoviário florestal por meio da otimização dos tempos de ciclo de transporte.

Leite (2002) desencadeou um trabalho que minimizou os custos de transportes para a colheita de reflorestamentos, com enfoque nos aspectos operacionais que definem as características técnicas das estradas.

Souza et al. (2002) objetivaram analisar e avaliar a eficiência do transporte principal de madeira comparando os resultados gerados pela

programação matemática com o transporte de madeira realizado no ano de 1996.

Berger et al. (2003) comentam que a complexidade do planejamento do transporte florestal de madeira leva ao desenvolvimento de métodos que auxiliem na determinação das melhores rotas a serem seguidas por caminhões, para se conseguir um menor custo possível para um máximo volume de madeira posto no pátio.

Rodrigues (2004) desenvolveu um algoritmo com base no SA para resolver problemas de planejamento florestal comparando-o com os resultados obtidos pelo algoritmo exato *branch-and-bound*.

Binoti (2010) avalia a capacidade de solução dos AG para problemas de regulação florestal, com a inclusão de características ambientais e sociais visando o manejo da paisagem e obtendo resultados eficientes.

A maioria dos trabalhos de otimização florestal empregando meta-heurísticas estão voltados aos casos de regulação florestal, sendo ainda escassa a literatura direcionada aos problemas relacionados à logística de entrega de matéria-prima florestal, principalmente ao caso de escalonamento de motoristas.

3. MATERIAIS E MÉTODOS

3.1. LOCAL DE ESTUDO

Esta pesquisa foi desenvolvida em uma prestadora de serviços responsável pelo transporte de madeira da regional Guanhões da Celulose Nipo-Brasileira S. A. (CENIBRA), localizada no leste de Minas Gerais. A sede da empresa terceirizada e a unidade industrial estão, ambas, localizadas no município de Belo Oriente – MG, a 236 km da capital do estado, Belo Horizonte (Figura 1).




Figura 1. Localização Ceníbra S.A.

As áreas que compõem a Unidade de Manejo Florestal da CENIBRA estão distribuídas por 54 municípios e organizadas em três unidades administrativas, denominadas: Regional Rio Doce (em laranja ao centro), Regional Guanhões (localizada ao norte em amarelo) e Regional Nova Era (em azul ao sul), apresentados na Figura 2. A área de plantios, própria e arrendada, totaliza 255.271 hectares, sendo 50,52% de plantios do gênero *Eucalyptus*, 40,45% de reserva legal e áreas de preservação permanente e o restante constitui estradas, aceiros, edificações, etc.

A unidade industrial é abastecida com madeira proveniente de áreas próprias e arrendada, além de madeira adquirida de pequenos produtores em sistema de fomento, que representa em torno de 10% da madeira consumida.

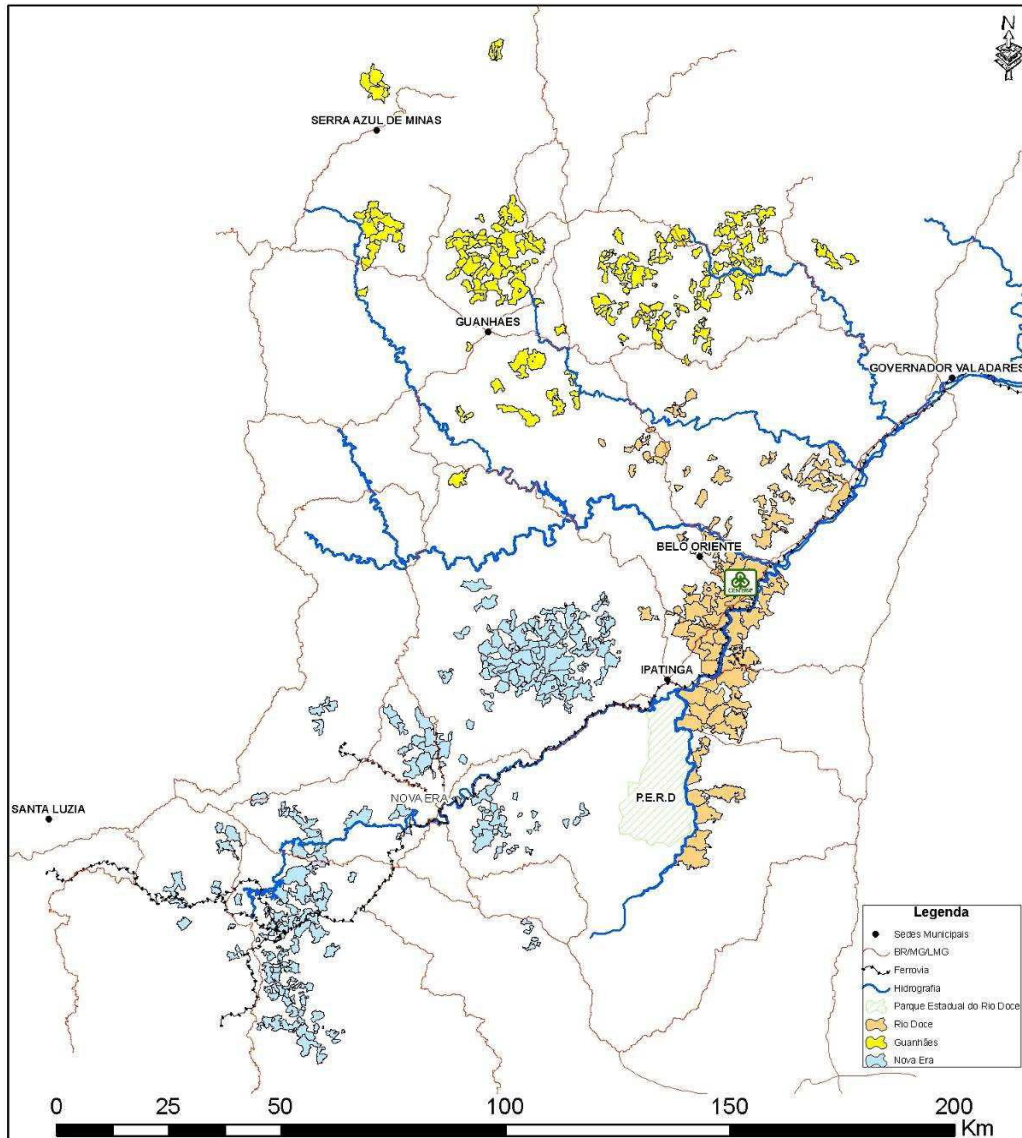


Figura 2. Localização das áreas florestais da empresa no leste de Minas Gerais.

A indústria recebe madeira vinda diretamente das unidades de produção e dos pátios de madeira das regionais. A matéria-prima é transportada através de rodovias pavimentadas e não pavimentadas e ferrovias. Seis empresas terceirizadas são responsáveis por esta atividade.

3.2. DESCRIÇÃO DO MODELO DE TRANSPORTE DE MADEIRA UTILIZADO

Problemas de escalonamento de motorista têm como objetivo designar aos motoristas a atividade de conduzir veículos previamente determinados, do ponto de origem ao ponto final, de maneira que todas as viagens programadas pela empresa sejam atendidas com o menor custo possível e durante certo período de tempo. A seguir, são apresentadas algumas definições utilizadas na pesquisa:

1. Trecho: condução da CVC entre os possíveis pontos de trocas dos motoristas;
2. Viagem: condução da CVC do pátio da empresa até determinado ponto de carregamento no campo e retornar ao pátio, realizando antes, o descarregamento na indústria;
3. Jornada: Atividade realizada pelo motorista do momento em que ele abre seu diário de viagem até o momento em que este é fechado;
4. Escalas de serviço: é o conjunto de jornadas diárias consecutivas, que pode ser atribuído a um motorista;
5. Motorista: o funcionário contratado pela empresa para executar uma escala de serviço disponível;
6. Equipe de motoristas: formada por três motoristas responsáveis em conduzir uma determinada CVC, e;
7. Grupo: Caracterizado pelo ponto onde cada motorista deve iniciar e finalizar sua jornada.

A seguir é apresentado todo o contexto envolvendo a atividade de transporte de madeira.

3.2.1. Ciclo Operacional

O transporte de madeira na regional de Guanhães é realizado por dois tipos de CVC's apresentados na Figura 3. O tritrem, capaz de transportar madeira de 6 m e o rodotrem transportando madeira de 2,2 e, ou, de 6 m.



<p>Tritrem</p>	 <p>Comprimento Máximo: 30,00m</p>	<p>6t+17t+17t+17t+17t PBTC = 74t</p>
<p>Rodotrem</p>	 <p>Comprimento Máximo: 30,00m</p>	<p>6t+17t+17t+17t+17t PBTC = 74t</p>

Figura 3. Combinações de veículos de carga utilizados no transporte.

O ciclo operacional do transporte (Figura 4) inicia-se no pátio da empresa terceirizada (ponto 1), localizado próximo ao trevo de Belo Oriente, a 2 km de distância da indústria. As trocas de turno são realizadas no pátio da empresa terceirizada, nos municípios de Belo Oriente (ponto 2), Açucena (ponto 3) e Sapucaia (ponto 4) e no ponto de apoio (ponto 5).

Saindo do pátio, o motorista chega ao ponto de apoio onde o controlador faz o encaminhamento da CVC ao ponto de carregamento no campo (ponto 6). A distância média de transporte (DMT) entre indústria e projetos é obtida através de uma média ponderada da distância e volume transportado de todos os projetos da regional e seu valor é de 270 km (ida e volta).

Atualmente, a empresa possui quatro pontos de carregamento, e cabe ao controlador direcionar a frota a um desses locais. Os fatores que levam o controlador a tomar tal decisão são: ordem de chegada, tipo de composição, modo como a madeira está depositada no campo (pilhas altas ou baixas obtendo, respectivamente, uma maior ou menor produtividade da grua devido ao número de movimentação), produtividade do operador de grua, manutenção de grua, filas no carregamento, obstrução da estrada, deslocamento da máquina para outro ponto de carregamento e carga horária do motorista (quanto mais próximo ao fim da sua jornada mais perto deverá ser o carregamento).

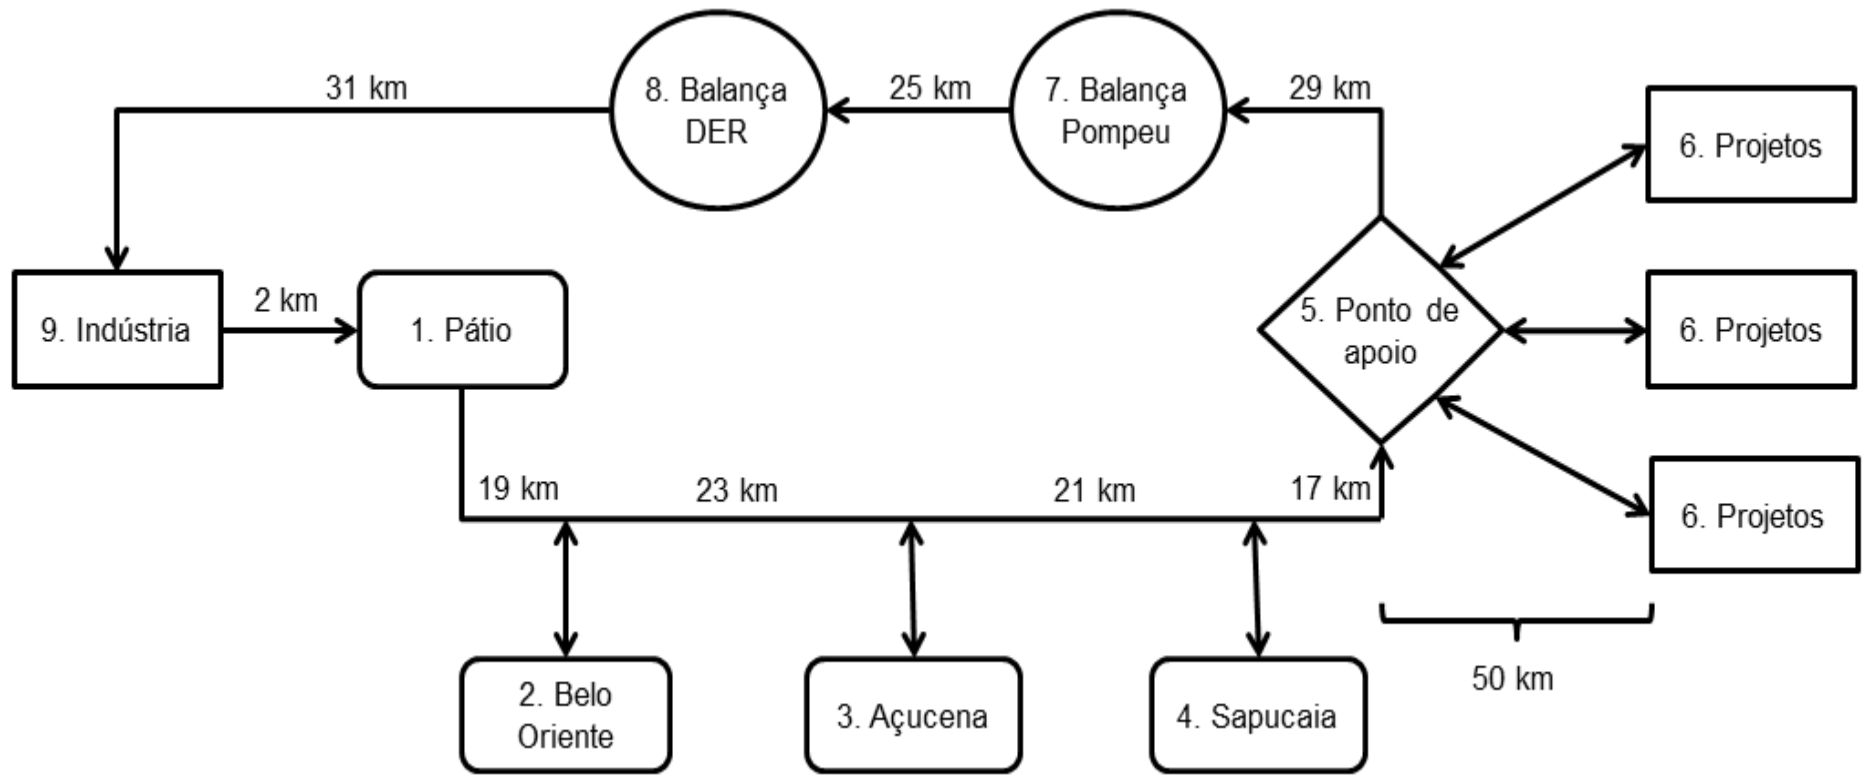


Figura 4. Fluxograma ciclo operacional

No local definido pelo controlador, a CVC é carregada, o motorista faz a conferência e amarração da carga e procede ao caminho de volta. Nesse trajeto, a CVC passará pela balança (ponto 8) do Departamento de Estradas e Rodagem de Minas Gerais (DER-MG). Para que não haja inconformidades com o excesso de carga e geração de multas, primeiramente, a CVC passa pelo pátio Pompeu (ponto 7), onde é realizada uma pesagem por eixo do veículo, podendo ser adicionado ou retirado madeira da carga através de uma grua existente no local, sempre procurando otimizar a eficiência de carga do veículo e a produtividade do transporte.

Ao chegar à indústria (ponto 9), é obtido o Peso Bruto Total da Composição (PBTC) e a equipe de recebimento de madeira indica em qual dos pontos disponíveis será realizado o descarregamento. Em seguida, é realizada a limpeza da CVC, o abastecimento e novamente a passagem pela balança, obtendo o peso líquido transportado.

O motorista chega então ao pátio onde é realizada a manutenção (lubrificação, calibragem, regulagem de freio e conserto de avarias), encerrando assim o ciclo operacional de transporte.

Na Tabela 1 estão relacionadas às distâncias em quilômetros (km) entre cada ponto da viagem:

Tabela 1. Distância (km) entre os trechos do ciclo de viagem dos veículos de transporte

DMT	DMT								
Pátio	133	Pátio							
Belo Oriente	114	19	Belo Oriente						
Açucena	91	42	23	Açucena					
Sapucaia	67	66	47	24	Sapucaia				
Ponto de Apoio	50	83	64	41	17	Ponto de Apoio			
Balança Pompéu	79	54	35	12	12	29	Balança Pompéu		
Balança DER	104	29	10	13	37	54	25	Balança DER	
Indústria	135	2	21	44	68	85	56	31	Indústria

Se, no decorrer da viagem, houver algum problema mecânico (pneu furado, empenamento de roda, quebra da mola de suspensão, da balança, caixa de marchas, diferencial, bloqueio, etc.), é acionado o socorro via rádio ou se, a CVC não possuir rádio, o motorista acena para um carro que possua e este solicita o socorro.

3.2.2. Restrições Operacionais

A empresa possui um quadro de 150 motoristas ativos e 18 motoristas em férias ou em afastamento, sendo que mensalmente uma média de 15 motoristas entra de férias.

A frota possui 54 CVC's, sendo que quatro ficam de reserva, prontos para entrarem em operação, quando necessário. Cada veículo é conduzido por uma equipe de três motoristas trabalhando em turnos alternados na escala 4 x 2 (quatro dias de trabalho e dois de descanso).

A carga horária diária do motorista, em acordo feito entre as partes, é de 12h de trabalho com uma hora de refeição, que pode ser realizada a qualquer momento de sua jornada, sendo, o mais comum, no carregamento ou descarregamento. O motorista só retorna ao trabalho depois de, no mínimo, 11h de folga. A empresa terceirizada tem como meta a realização de uma viagem completa dentro da jornada de cada motorista.

No contrato de terceirização do serviço, a velocidade média programada deve ser entre 30 e 35 km/h. O tempo de carregamento deve estar em um intervalo de 00h50min a 01h12min, o de descarregamento entre 1h a 01h20min e eficiência operacional entre 83 e 90%. Como a indústria recebe madeira vinda de outras regionais o intervalo para descarregamento é maior comparado ao carregamento.

3.2.3. Escala Diária e Mensal

No setor de tráfego, é montado um quadro de escala diária de serviços dos motoristas e, partindo desse, são montadas as escalas mensais (Tabela 2) e anuais (conjunto das escalas mensais). Cada um dos motoristas do veículo

recebe uma letra (A, B e C) que está associada à sua tarefa no respectivo dia, ou seja, quais motoristas trabalharão na 1ª e na 2ª parte do dia e quais estarão de folga.

Tabela 2. Escala mensal de trabalho

Agosto																			01	02	03	04	05
	06	07	08	09	10	11	12	13	14	15	16	17	18	19	20	21	22	23					
	24	25	26	27	28	29	30	31															
07:00/19:00	A	A	B	B	C	C	A	A	B	B	C	C	A	A	B	B	C	C					
19:00/07:00	C	C	A	A	B	B	C	C	A	A	B	B	C	C	A	A	B	B					
FOLGA	B	B	C	C	A	A	B	B	C	C	A	A	B	B	C	C	A	A					

Também foi criada uma escala de horários indicando as saídas de cada CVC. Na Figura 5 é exemplificado o horário de saída de quatro CVC's diferentes e quais motoristas estarão trabalhando na 1ª e na 2ª parte do dia (amarelo) e o que estará de folga.




Figura 5. Escala de trabalho da frota e dos motoristas.

3.2.4. Trocas de Turno

A empresa terceirizada procura formar a equipe responsável por cada veículo de acordo com o local de residência dos motoristas. Os moradores de Ipatinga, Naque, Periquito, Cachoeira Escura e regiões vizinhas realizam suas

trocas no Pátio, enquanto no ponto de apoio, são realizadas as trocas dos que residem nas regiões de Virgínoópolis, Guanhões e Divinolândia. Já em Açucena, Belo Oriente e Sapucaia são feitas as trocas dos motoristas que moram nesses respectivos municípios. A quantidade de CVC's e os locais onde são realizadas suas trocas de turnos são apresentados na Tabela 3.

Tabela 3. Pontos de trocas de turnos

Local	Intervalo (horas)	Quantidade CVC's
Pátio	02h00min às 07h00min 14h00min às 19h00min	17
Ponto de Apoio	00h00min às 07h00min 12h00min às 19h00min	23
Açucena	01h00min às 03h00min 13h00min às 15h00min	3
Belo Oriente	02h00min às 04h00min 14h00min às 16h00min	4
Sapucaia	02h00min às 03h00min 14h00min às 15h00min	3
Total		50

Ao aproximar do local de troca, o motorista que está finalizando sua viagem entra em contato com o controlador do ponto de apoio ou do setor de tráfego pedindo para que o próximo motorista que assumirá a CVC, informando a hora de chegada. Em algumas situações o próprio motorista realiza esse contato.

3.2.4.6. Trocas de turno no pátio

As jornadas iniciadas no pátio começam por volta das 2h, e até às 7h praticamente todas as CVC's já saíram (Tabela 3), salvo os que estão em manutenção. Os motoristas gastam de 00h10min a 00h30min para chegar de

suas casas até o pátio, e esse percurso é feito a pé, de bicicleta, moto, veículo próprio, ônibus de linha ou de carona. Não havendo nenhuma comunicação de atraso, o motorista se desloca até o pátio para, assim que vencer suas horas de folga, abrir seu diário de viagem aguardando o veículo chegar para então iniciar uma viagem. Se houver um adiantamento de viagem e as horas de folga do próximo condutor ainda não venceram, o veículo fica parado aguardando esse término.

3.2.4.7. Trocas de turno no ponto de apoio

No ponto de apoio, a partir das 0h, já se iniciam as jornadas (Tabela 3). Com uma hora de antecedência, o motorista fica ciente de quando seu veículo chegará, e então, de carona ou com o seu carro ou moto, sai de sua casa levando de 00h10min a 00h30min para chegar ao ponto de troca. O ponto de apoio está localizado a 83 km de distância do pátio.

3.2.4.8. Trocas de turno em Belo Oriente

Em Belo Oriente, as trocas de turno são feitas na saída da cidade, sentido Virginópolis, nos dois lados da pista, em frente ao circuito de *motocross*, distante a 19 km do pátio, ou, quando carregado, no posto do trevo na chegada da cidade distante 16 km do pátio. A comunicação entre a equipe de motoristas é realizada com, aproximadamente, uma hora de antecedência, e este leva de 00h10min a 00h30min para sair de sua casa e chegar ao ponto de troca, fazendo o caminho a pé, de bicicleta, moto ou carro. Os turnos se iniciam no intervalo das 2h às 4h (Tabela 3).

3.2.4.9. Trocas de turno em Açucena

Os pontos de troca das frotas de Açucena são feitos no 1º ou 2º trevo de acesso à cidade, distantes 41 e 43 km do pátio, respectivamente. A escolha entre os dois trevos é feita levando em consideração a quantidade de carretas

ali paradas. Os turnos iniciam-se por volta das 3h (Tabela 3) e, por meio de moto ou carro, o motorista se desloca da sua casa até o ponto de troca gastando de 00h10min a 00h20min.

3.2.4.10. Trocas de turno em Sapucaia

Por ter uma grande área de estacionamento, as trocas de turno no município de Sapucaia são feitas no Restaurante Sapucaia, a 66 km do pátio. Das residências dos motoristas até o ponto de troca, são gastos de 00h10min a 00h20min realizados a pé. Os turnos se iniciam das 2h às 3h (Tabela 3). O contato entre as equipes de motoristas, alertando a hora de chegada ao ponto de troca, é feito com 00h40min de antecedência.

3.3. COLETA DE DADOS

A coleta de dados foi realizada no período de julho a setembro de 2011, em uma empresa terceirizada para o transporte de madeira da empresa CENIBRA, que é responsável pelo transporte de madeira da regional de Guanhães à indústria.

Foram realizados estudos, *in loco*, de tempos e movimentos com o método contínuo, utilizando pranchetas para anotação dos dados e cronômetro digital, evitando qualquer tipo de interferência do pesquisador, que poderiam descaracterizar as atividades desempenhadas no cotidiano da empresa.

Realizou-se um levantamento das distâncias e dos tempos consumidos entre cada etapa da viagem percorrida pelo veículo; do número de motoristas ativos e inativos, ou seja, os que se encontram em férias ou em licença médica; do número de veículos disponíveis para a atividade; de todos os locais onde são realizadas as trocas de turno; de quantos motoristas e a que horas eles realizam as trocas de turnos em cada ponto.

Utilizando o conjunto de números naturais, excluindo o zero, N^* , atribuíram-se códigos de identificação a todos os locais do ciclo de viagem (Tabela 4). Também foram codificados os motoristas ativos, os veículos

disponíveis para realização da atividade e o grupo a qual pertence à equipe de acordo com seu ponto de troca.

Tabela 4. Codificação atribuída aos locais do ciclo de viagem

Locais	Código
Pátio	1
Belo Oriente	2
Açucena	3
Sapucaia	4
Ponto de Apoio	5
Projeto	6
Pompéu	7
Balança DER	8
Indústria	9

As distâncias mensuradas foram relacionadas e em seguida transformadas em horas necessárias para realizar o deslocamento entre cada ponto, levando em consideração os valores estipulados no contrato entre CENIBRA e empresa terceirizada, como: velocidade média, eficiência operacional, tempo de carregamento e descarregamento e tempos acessórios (caracterizado pelo tempo despendido com funções obrigatórias, porém não diretamente relacionadas com a operação, como paradas pessoais, por exemplo).

Com base nos dados de saída dos veículos e motoristas em cada ponto (Tabela 4), foi elaborada uma planilha apresentada na Tabela 5. Esta planilha contém os trechos correspondentes à divisão em etapas da viagem realizada. Importante salientar que os motoristas que compõem cada uma das frotas estão reunidos em grupos de acordo com suas moradias. Devido a isso, eles, obrigatoriamente, devem iniciar e finalizar seus turnos no seu grupo, mas nada impede que no meio de suas tarefas ele atenda um trecho que pertença a um grupo diferente. Esta contém, ainda, o código do veículo, o ponto inicial e

final, seus respectivos horários de saída e chegada de cada trecho de sua viagem e o grupo a qual pertencem.

Tabela 5. Exemplo de viagens realizadas por um motorista

Trechos	Nº Veículo	Ponto Inicial	Ponto Final	Hora Saída	Hora Chegada	Duração do ciclo	Grupo
69	18	Belo Oriente	Ponto apoio	02h00min	04h31min	02h31min	2
70	18	Ponto apoio	Ponto apoio	04h31min	09h43min	05h12min	2
71	18	Ponto apoio	Belo Oriente	09h43min	12h14min	02h31min	2
72	18	Belo Oriente	Pátio	12h14min	14h43min	02h29min	2
73	18	Pátio	Pátio	14h43min	15h07min	00h24min	2
74	18	Pátio	Belo Oriente	15h07min	15h52min	00h45min	2

Pode-se observar que os trechos 69 a 74 são realizados pelo veículo 18, conduzidos por motorista do grupo 2. Ainda observa-se que o primeiro trecho realizado pelo motorista é de Belo Oriente (ponto 2) até o ponto de apoio (ponto 5). O trecho seguinte é do ponto de apoio ao ponto de apoio, realizando o carregamento no campo (ponto 6). O terceiro trecho consiste em ir do ponto de apoio à Belo Oriente já que o retorno é feito pela mesma rodovia. O quarto trecho tem como ponto de saída o município de Belo Oriente e o ponto de chegada se dá no pátio (ponto 1) passando pela indústria e efetuando o descarregamento. No quinto trecho não se percorre distância alguma, porém esse trata do tempo em que o veículo estará em manutenção. O último trecho percorrido é do pátio até o município de Belo Oriente finalizando, assim, a viagem. Considerando o levantamento realizado por este estudo o total de horas das jornadas diárias de cada motorista é de 13h52min.

A planilha relacionando os trechos conduzidos pelos motoristas foi exportada em formato “*.txt”, servindo de entrada de dados para resolução do problema pelas diferentes meta-heurísticas (Figura 6).

n	m	p	he	ht		
c_1	c_2	\dots	c_p			
d_1	v_1	pi_1	pf_1	hs_1	hc_1	g_1
d_2	v_2	pi_2	pf_2	hs_2	hc_2	g_2
\dots						
d_n	v_n	pi_n	pf_n	hs_n	hc_n	g_n

Figura 6. Formato de entrada de dados.

Em que:

n : número de trechos;

m : número de motoristas disponíveis;

p : número de grupos;

he : horário máximo de trabalho de cada motorista sem hora extra;

ht : horário máximo de trabalho de cada motorista incluindo as horas extras;

c_1, c_2, \dots, c_p : número de motoristas de cada grupo;

d_j : identificador do trecho j ;

v_j : veículo que executa o trecho j ;

pi_j : ponto inicial do trecho j ;

pf_j : ponto final do trecho j ;

hs_j : horário de saída do ponto inicial do trecho j ;

hc_j : horário de chegada no ponto final do trecho j ;

g_j : grupo do trecho j .

3.4. CONSTRUÇÃO DO MODELO

O problema consiste em distribuir n trechos de viagens a m motoristas disponíveis. Cada trecho é formado por um identificador, um veículo, um ponto inicial e final, um horário de saída e chegada e um grupo. O motorista inicia e termina a viagem em um ponto referente ao seu grupo. Uma solução do problema considera que cada trecho seja atribuído a apenas um motorista e que todos os trechos sejam atendidos.

Para a avaliação de uma solução foi considerada a seguinte função objetivo:

$$\begin{aligned} \text{Min } f(S) = & \omega_1 \text{MU} + \omega_2 \sum_{i=1}^m \text{HE}_i + \omega_3 \sum_{i=1}^m \text{TO}_i + \omega_4 \sum_{i=1}^m \text{TV}_i + \\ & \omega_5 \sum_{i=1}^m \text{HT}_i + \omega_6 \sum_{i=1}^m \text{TP}_i + \omega_7 \sum_{i=1}^m \text{TG}_i + \omega_8 \sum_{i=1}^m \text{TS}_i \end{aligned} \quad (1)$$

Em que:

MU = número de motoristas utilizados para atender todos os trechos;

HE_{*i*} = quantidade de horas extras do motorista *i*;

TO_{*i*} = quantidade de horas ociosas do motorista *i*;

TV_{*i*} = número de trocas de veículos do motorista *i*;

HT_{*i*} = quantidade de horas que excedem o limite permitido ao motorista *i*;

TP_{*i*} = número de trocas de pontos do motorista *i*;

TG_{*i*} = número de trechos atendidos pelo motorista *i* cujos grupos são diferentes do seu;

TS_{*i*} = quantidade de horas de sobreposição para o motorista *i*, e;

ω_{*i*} = pesos caracterizando a importância dos 8 objetivos distintos.

Foram definidos 5 cenários distintos (Tabela 6), com diferentes objetivos, com o intuito de gerar diferentes soluções para o problema. Os cenários são caracterizados por meio da utilização de valores diversos para cada “objetivo” (termo) na função de avaliação.

Na função $f(S)$, os quatro primeiros termos foram reduzidos ao máximo, pois os mesmos refletem os custos operacionais da empresa. Já para os quatro últimos, procurou-se a eliminação dos mesmos, pois caracterizam uma solução inviável em termos práticos.

Tabela 6. Cenários, pesos e objetivos

Cenário	ω_1	ω_2	ω_3	ω_4	ω_5	ω_6	ω_7	ω_8	Objetivo
1	1	0	0	0	100	1500	1500	100	Reduzir número de motoristas
2	0	1	0	0	100	1500	1500	100	Reduzir horas extras
3	0	0	1	0	100	1500	1500	100	Reduzir horas ociosas
4	0	0	0	1	100	1500	1500	100	Reduzir troca de veículos
5	10	5	2	10	100	1500	1500	100	Solução “equilibrada”

Os testes foram realizados em cinco cenários com objetivos distintos; Cenário 1: reduzir o número de motoristas, Cenário 2: reduzir a quantidade de horas extras dos motoristas, Cenário 3: reduzir o número de horas ociosas dos motoristas, Cenário 4: reduzir o número de trocas de veículos feitas por motoristas e Cenário 5: solução “equilibrada”.

3.5. RESOLUÇÃO DO MODELO

Em posse do arquivo de entrada de dados, lançou-se mão de ferramentas otimizadoras para poder comparar, avaliar e por fim possibilitar o planejamento de ações que visam tornar mais eficiente o emprego dos recursos que a empresa dispõe.

Assim, foram implementados 5 (cinco) métodos: Algoritmo Genético, Algoritmo Memético, *Clustering Search*, *Greedy Randomized Adaptive Search Procedure* e *Simulated Annealing*.

Para avaliar o desempenho desses métodos, foi utilizada a entrada de dados obtida por meio da coleta de dados realizada nesta pesquisa. Para cada método foram usados parâmetros distintos, obtidos empiricamente. Todos os métodos foram implementados em C++ e os testes foram realizados em um PC com processador *Intel Core i5* de 2,66 GHz e 4GB de RAM.

Cada método foi executado 10 vezes para cada cenário.

A Figura 7 apresenta o AG implementado para resolução do problema de escalonamento de motoristas. Os valores dos parâmetros usados foram: $AG_{max} = 2500$, $Pop = 400$, $Eli = 8\%$, $Cro = 200$ e $Mut = 20$.

```

1. DADO ( $AG_{max}$ , Pop, Eli, Cro e Mut) FAÇA
2.  $P \leftarrow$  Uma população inicial com Pop indivíduos;
3.  $nP \leftarrow \emptyset$ ;
4.  $g \leftarrow 0$ ;
5. ENQUANTO ( $g \leq AG_{max}$ ) FAÇA
6.    $g \leftarrow g + 1$ ;
7.   PARA  $i \leftarrow 1$  ATÉ Cro FAÇA
8.      $p1 \leftarrow$  um indivíduo de entre os Eli melhores de P;
9.      $p2 \leftarrow$  outro indivíduo qualquer de P;
10.     $f \leftarrow$  CROSSOVER ( $p1, p2$ );
11.     $nP \leftarrow nP \cup \{f\}$ ;
12.  FIM-PARA;
13.  PARA  $i \leftarrow 1$  ATÉ Mut FAÇA
14.     $f \leftarrow$  um indivíduo qualquer de nP;
15.     $f \leftarrow$  MUTAÇÃO ( $f$ );
16.  FIM-PARA;
17.   $nP \leftarrow nP \cup \{f\}$ ;
18.   $P \leftarrow P^* \rightarrow P^* \subseteq \{P \cup nP\}, |P^*| = Pop$ ;
19.   $nP \leftarrow \emptyset$ ;
20. FIM-ENQUANTO;
21.  $I^* \leftarrow$  melhor indivíduo de P;
22. RETORNAR ( $I^*$ );

```

Figura 7. Algoritmo Genético implementado.

Em que:

AG_{max} : número máximo de gerações;

Pop: tamanho da população;

Cro: número de cruzamentos;

Mut: número de mutações, e;

Eli: tamanho percentual da população elite.

O AM implementado é apresentado na Figura 8 e os parâmetros utilizados são: $AM_{max} = 17$, $Pop = 300$, $Eli = 8\%$, $Cro = 130$, $Mut = 5$, $T_0 = 10$, $T_C = 0,01$, $SA_{max} = 7$ e $\alpha = 0,96$.

```

1. DADO ( $AM_{max}$ , Pop, Eli, Cro e Mut) FAÇA
2.  $P \leftarrow$  Uma população inicial com Pop indivíduos;
3.  $nP \leftarrow \emptyset$ ;
4.  $g \leftarrow 0$ ;
5. ENQUANTO ( $g \leq AG_{max}$ ) FAÇA
6.    $g \leftarrow g + 1$ ;
7.   PARA  $i \leftarrow 1$  ATÉ Cro FAÇA
8.      $p1 \leftarrow$  um indivíduo de entre os Eli melhores de P;
9.      $p2 \leftarrow$  outro indivíduo qualquer de P;
10.     $f \leftarrow$  CROSSOVER ( $p1, p2$ );
11.     $f \leftarrow$  BUSCA-LOCAL ( $f$ );
12.     $nP \leftarrow nP \cup \{f\}$ ;
13.  FIM-PARA;
14.  PARA  $i \leftarrow 1$  ATÉ Mut FAÇA
15.     $f \leftarrow$  um indivíduo qualquer de  $nP$ ;
16.     $f \leftarrow$  MUTAÇÃO ( $f$ );
17.  FIM-PARA;
18.   $nP \leftarrow nP \cup \{f\}$ ;
19.   $P \leftarrow P^* \rightarrow P^* \subseteq \{P \cup nP\}, |P^*| = Pop$ ;
20.   $nP \leftarrow \emptyset$ ;
21. FIM-ENQUANTO;
22.  $I^* \leftarrow$  melhor indivíduo de P;
23. RETORNAR ( $I^*$ );

```

Figura 8. Algoritmo Memético implementado.

Em que:

AM_{max} : número máximo de gerações;

Pop: tamanho da população;

Cro: número de cruzamentos;

Mut: número de mutações, e;

Eli: tamanho percentual da população elite.

Na Figura 9 é apresentado o CS implementado, cujos parâmetros utilizados são os seguintes: $Cl_t = 10$, $v_{max} = 7$, $r_{max} = 3$, $T_0 = 20000$, $T_f = 0,01$, $SA_{max} = 1000$ e $\alpha = 0,975$.

```

1. DADO ( $Cl$ ,  $v_{max}$  e  $r_{max}$ );
2. GERAR (uma solução  $S$  por meio de uma meta-heurística);
3. ENCONTRAR (o cluster  $C_j$  mais similar a  $S$ );
4.  $v_j \leftarrow v_j + 1$ ;
5. ATUALIZAR (o centro do cluster  $C_j$ );
6. SE  $v_j \geq v_{max}$  ENTÃO
7.    $v_j \leftarrow 1$ ;
8.   SE  $r_j \geq r_{max}$  ENTÃO
9.     PERTUBAR ( $c_j$ )
10.     $r_j \leftarrow 0$ ;
11.   SENÃO
12.      $c_j' \leftarrow$  BUSCA-LOCAL ( $c_j$ );
13.     SE  $f(c_j') < f(c_j)$  ENTÃO
14.        $c_j \leftarrow c_j'$ ;
15.        $r_j \leftarrow 0$ ;
16.     SENÃO
17.        $r_j \leftarrow r_j + 1$ ;
18.     FIM-SE;
19.   FIM-SE;
20. FIM-SE;
21. SE critério de parada satisfeito ENTÃO
22.   RETORNAR (o melhor  $c_j$ );
23. SENÃO
24.   voltar ao passo 2;
25. FIM-SE;

```

Figura 9. *Clustering Search* implementado.

Em que:

Cl : quantidade de *clusters* utilizados;

v_{max} : volume máximo dos *clusters*, e;

r_{max} : índice de ineficácia.

A Figura 10 apresenta o GRASP implementado para o problema que possui como parâmetros: $L = 100$ e $G_{max} = 100$.

```

1. DADO ( $G_{max}$  e LRC) FAÇA
2.  $f^* \leftarrow \infty$ ;           {Inicializar a melhor FO}
3.  $Iter \leftarrow 0$ ;         {Número de iterações}
4. ENQUANTO ( $Iter \leq G_{max}$ ) FAÇA
5.    $Iter \leftarrow Iter + 1$ ;
6.    $S \leftarrow$  HEURÍSTICA_DE_CONSTRUÇÃO (LRC);
7.    $S \leftarrow$  BUSCA_LOCAL (S);
8.   SE ( $f(S) < f^*$ )
9.      $f^* \leftarrow f(S)$ ;
10.     $S^* \leftarrow S$ ;
11.   FIM-SE;
12. FIM-ENQUANTO;
13. RETORNAR ( $S^*$ );

```

Figura 10. GRASP implementado.

Em que:

G_{max} : número máximo de iterações, e;

LRC: tamanho da Lista Restrita de Candidatos.

O algoritmo do SA implementado é apresentado na Figura 11. Nela, também são apresentados os parâmetros utilizados para resolução do problema. São eles, SA_{max} : número de iterações para atingir o equilíbrio térmico no valor de 1000; T_0 : temperatura inicial de 20000; T_c : temperatura de congelamento de 0,01; e α : taxa de resfriamento sendo de 0,975.

```

1. DADO ( $SA_{max}$ ,  $T_0$ ,  $T_c$  e  $\alpha$ ) FAÇA
2.  $S \leftarrow$  solução aleatória;
3.  $S^* \leftarrow S$ ; {Melhor solução obtida até então}
4.  $IterT \leftarrow 0$ ; {Número de iterações na temperatura T}
5.  $T \leftarrow T_0$ ; {Temperatura corrente}
6. ENQUANTO ( $T > T_c$ ) FAÇA
7. ENQUANTO ( $IterT < SA_{max}$ ) FAÇA
8.  $IterT \leftarrow IterT + 1$ ;
9. GERAR (um vizinho  $S' \in N(S)$ );
10.  $\Delta \leftarrow f(S') - f(S)$ ;
11. SE ( $\Delta < 0$ )
12.  $S \leftarrow S'$ ;
13. SE ( $f(S') < f(S^*)$ )
14.  $S^* \leftarrow S'$ ;
15. FIM-SE;
16. SENÃO
17. TOMAR ( $x \in [0,1]$ );
18. SE ( $x < e^{-\Delta/T}$ )
19.  $S \leftarrow S'$ ;
20. FIM-SE;
21. FIM-SE;
22. FIM-ENQUANTO;
23.  $T \leftarrow \alpha * T$ ;  $IterT \leftarrow 0$ ;
24. FIM-ENQUANTO;
25. RETORNAR ( $S^*$ );

```

Figura 11. *Simulated Annealing* implementado.

Em seguida foi calculado o desvio padrão para cada método em cada cenário.

$$\text{Desvio (\%)} = \left(\frac{f(S)_m - f(S)^*}{f(S)^*} \right) \times 100 \quad (2)$$

Em que:

$f(S)_m$ = função objetivo média, e;

$f(S)^*$ = melhor função objetivo.

4. RESULTADOS E DISCUSSÃO

4.1. DIAGNÓSTICO DA ATUAL SITUAÇÃO DO TRANSPORTE DE MADEIRA NA EMPRESA

Por meio do levantamento realizado, a empresa terceirizada responsável pelo transporte de madeira da regional Guanhães tem em seu quadro uma frota de 50 veículos conduzidos por 150 motoristas distribuídos na proporção de três motoristas para cada veículo.

A jornada de serviços, combinada em comum acordo entre empresa terceirizada e motoristas é de oito horas acrescidas de quatro horas extras, totalizando 12h, já inclusa uma hora para refeição. Porém, pelas condições levantadas pelo estudo, onde considerou os limites superiores estipulados em contrato entre CENIBRA e empresa terceirizada, de: velocidade média, eficiência operacional, tempos de carregamento e descarregamento, tempo médio de manutenção e tempos acessórios; a jornada de trabalho é de 13h52min. Portanto, verificando a realidade atual, a empresa terceirizada consegue um rendimento superior ao contratado. Relativo às horas extras realizadas por todos os motoristas, tem-se uma média diária total de 01h03min enquanto que a média de horas excedentes (além das 12 horas) no dia de todos os motoristas é de 00h51min.

4.2. COMPARAÇÃO ENTRE AS META-HEURÍSTICAS USADAS NA OTIMIZAÇÃO DO ESCALONAMENTO DE MOTORISTAS

Os resultados obtido pelas meta-heurísticas para cada cenário, são apresentados nas Tabelas 7 a 11. As tabelas apresentam ainda: melhor função objetivo obtida ($f(S)^*$); função objetivo média ($f(S)_m$); desvio da função objetivo, em porcentagem ($D(\%)$); e o tempo médio de execução, em segundos (T_m).

Tabela 7. Resultados das meta-heurísticas para o Cenário 1

Meta-heurística	f(S)[*]	f(S)_m	D (%)	T_m (s)
Algoritmo Genético	92	99,7	8,369	197,31
Algoritmo Memético	89	90,0	1,236	266,52
Clustering Search	89	89,8	0,899	78,95
GRASP	94	96,4	1,744	124,45
Simulated Annealing	91	92,1	1,209	59,75

Nesse primeiro cenário, cujo objetivo é a redução do número de motoristas, o CS foi o método de melhor resultado médio e de menor desvio mostrando ser um método preciso. O AG gerou resultados médios 11,02% maiores do que o CS além de ser o método de menor precisão dentre os cinco observados. Analisando o tempo computacional, o SA destacou-se resolvendo, em média, o algoritmo em menos de um minuto.

Tabela 8. Resultados das meta-heurísticas para o Cenário 2

Meta-heurística	f(S)[*]	f(S)_m	D (%)	T_m (s)
Algoritmo Genético	0	181,73	-	167,10
Algoritmo Memético	1,19	1,69	42,353	273,22
Clustering Search	0	0	0	79,65
GRASP	0	0	0	158,47
Simulated Annealing	0	0	0	61,57

Quando o objetivo foi a redução de horas extras (Cenário 2), o CS, GRASP e SA conseguiram eliminá-las. Eles se diferenciam apenas nos tempos médios de execução onde o CS e o GRASP foram 29,36% e 157,38%, respectivamente, superiores ao SA. Novamente o AG mostrou ser o método de pior resultado para o cenário.

Tabela 9. Resultados das meta-heurísticas para o cenário 3

Meta-heurística	f(S)[*]	f(S)_m	D (%)	T_m (s)
Algoritmo Genético	11,05	20,96	89,719	173,85
Algoritmo Memético	21,29	25,97	18,453	77,02
Clustering Search	0	0	0	77,02
GRASP	1,35	5,76	2,384	166,52
Simulated Annealing	0	0	0	61,57

Para o Cenário 3 em que o objetivo foi de reduzir as horas ociosas, com os melhores resultados aparecem o CS e SA, destacando o SA pelo melhor desempenho em tempos computacionais. Nesse cenário, o AM aparece pela primeira vez com os resultados piores do que o AG.

Tabela 10. Resultados das meta-heurísticas para o cenário 4

Meta-heurística	f(S)[*]	f(S)_m	D (%)	T_m (s)
Algoritmo Genético	69	102,3	48,26	172,46
Algoritmo Memético	27	29,8	10,37	279,86
Clustering Search	0	0	0	78,1
GRASP	3	5,6	1,281	164,96
Simulated Annealing	0	0,2	-	60,03

No Cenário 4, que teve como objetivo a redução do número de trocas de veículos realizadas pelos motoristas, novamente temos o CS, seguido pelo SA e GRASP com os melhores resultados. O AG mostrou ser o método menos preciso enquanto o AM foi o mais demorado.

Tabela 11. Resultados das meta-heurísticas para o cenário 5

Meta-heurística	f(S)[*]	f(S)_m	D (%)	T_m (s)
Algoritmo Genético	2240,88	2280,84	1,783	158,83
Algoritmo Memético	1161,04	1227,08	5,688	281,55
Clustering Search	1000	1000	0	71,21
GRASP	1121,36	1163,69	21,42	135,36
Simulated Annealing	1000	1023,91	2,391	62,34

Para o quinto cenário, cujos pesos foram equilibrados, o desempenho das meta-heurísticas não se alteram tendo como melhor método o CS, seguido do SA, com melhor tempo computacional. O AG gerou resultados 128,08% maiores do que o CS. O AM continuou sendo o método mais demorado com um tempo 4,52 vezes superior ao SA.

São apresentadas nas Tabelas de 12 a 16, de forma detalhada, as melhores soluções obtidas para cada método e cenário.

Tabela 12. Melhores soluções geradas para o Cenário 1

Algoritmo	Nº Motorista	Horas extras	Horas ociosas	Nº troca de veículo	Tempo médio de trabalho
Algoritmo Genético	92	40h11min	171h12min	128	07h18min
Algoritmo Memético	89	49h44min	155h21min	90	07h47min
Clustering Search	89	95h28min	89h58min	74	08h48min
GRASP	94	35h54min	174h52min	98	07h23min
Simulated Annealing	91	91h09min	87h51min	79	08h35min

Para o Cenário 1, onde o objetivo é de reduzir o número de motoristas, observa-se que todos os métodos geraram resultados próximos, conseguindo

uma redução de até 1,69 vezes no quadro de funcionário. Também foram próximos os valores dos tempos médios de serviços. Para este cenário é importante ressaltar o AG, AM e GRASP que mesmo possuindo uma hora extra por motorista baixa, variando de 00h23min a 00h34min o número de horas ociosas foi elevado, chegando perto de duas horas. Outro destaque importante é a quantidade de trocas de veículos gerada pelo AG, que pode trazer complicações para a viagem devido ao fato de parar o veículo constantemente.

Tabela 13. Melhores soluções geradas para o Cenário 2

Algoritmo	Nº Motorista	Horas extras	Horas ociosas	Nº troca de veículo	Tempo médio de trabalho
Algoritmo Genético	136	00h00min	149h32min	84	07h27min
Algoritmo Memético	127	01h11min	125h07min	58	05h27min
Clustering Search	110	00h00min	26h13min	58	06h32min
GRASP	146	00h00min	122h02min	55	04h45min
Simulated Annealing	139	00h00min	53h06min	51	05h22min

No Cenário 2, onde procurou-se a minimização das horas extras, apenas o AM não conseguiu eliminá-las porém seu resultado não o torna um método inviável. Comparando o número de motoristas o CS se destaca aparecendo com 17 unidades a menos do que o segundo melhor método (AM). O CS também se destaca nas horas ociosas, cada motorista teria apenas 00h14min de tempo sem atividade. O destaque negativo fica com o AG, detentor do maior número de trocas de veículos, de tempo médio de trabalho e de horas ociosas por motoristas.

Tabela 14. Melhores soluções geradas para o Cenário 3

Algoritmo	Nº Motorista	Horas extras	Horas ociosas	Nº troca de veículo	Tempo médio de trabalho
Algoritmo Genético	137	28h53min	11h03min	83	05h49min
Algoritmo Memético	141	15h45min	21h55min	40	04h55min
Clustering Search	100	45h25min	00h00min	0	06h56min
GRASP	149	26h09min	01h21min	3	04h39min
Simulated Annealing	139	29h42min	00h00min	0	04h58min

Quando se procurou redução de horas ociosas (Cenário 3), apenas o CS e o SA conseguiram sua total eliminação. Porém, se for analisado as horas ociosas de cada motorista, esse valor não excede aos 00h10min mostrando que todos os cinco métodos conseguiram ser eficientes para o objetivo proposto. O CS reduziu também o número de motoristas e conseguiu eliminar o número de trocas de veículo, entretanto foi o método com maior número de horas extras e de maior tempo médio de serviço.

Tabela 15. Melhores soluções geradas para o Cenário 4

Algoritmo	Nº Motorista	Horas extras	Horas ociosas	Nº troca de veículo	Tempo médio de trabalho
Algoritmo Genético	147	13h22min	142h06min	69	11h17min
Algoritmo Memético	140	18h45min	81h32min	27	04h57min
Clustering Search	100	39h52min	00h00min	0	06h56min
GRASP	150	17h00min	19h01min	3	04h37min
Simulated Annealing	138	25h39min	06h49min	0	05h04min

No Cenário 4, cujo objetivo é o de minimizar o número de trocas de veículos, apenas o AG e o AM não conseguiram reduzi-los significativamente. Estes, também, geraram os maiores valores para as horas ociosas por motorista, 00h58min e 00h35min, respectivamente. O CS conseguiu reduzir o número de motorista em 1/3 enquanto que nos demais a máxima redução foi de 12 unidades.

Tabela 16. Melhores soluções geradas para o Cenário 5

Algoritmo	Nº Motorista	Horas extras	Horas ociosas	Nº troca de veículo	Tempo médio de trabalho
Algoritmo Genético	139	02h22min	24h29min	79	05h15min
Algoritmo Memético	105	14h51min	03h22min	3	06h35min
Clustering Search	100	00h00min	00h00min	0	06h55min
GRASP	104	10h52min	03h28min	2	06h40min
Simulated Annealing	100	00h00min	00h00min	0	06h54min

No cenário onde os pesos foram equilibrados (Cenário 5) é possível observar que o CS e SA obtiveram resultados bastante próximos assim como o AM e o GRASP. Embora o AG fosse o método que gerou o menor tempo médio de trabalho este não conseguiu reduzir o número de motoristas, de horas ociosas e de trocas de veículos.

4.3. COMPARAÇÃO ENTRE AS META-HEURÍSTICAS E A SITUAÇÃO ATUAL DA EMPRESA

A Figura 12 representa um comparativo entre as melhores soluções de cada método no Cenário 5 com a situação atual da empresa. Este Cenário foi utilizado por possuir seus parâmetros “calibrados” de forma que as soluções fiquem equilibradas entre motoristas utilizados, horas extras, horas ociosas e trocas de veículos realizados pelos motoristas.

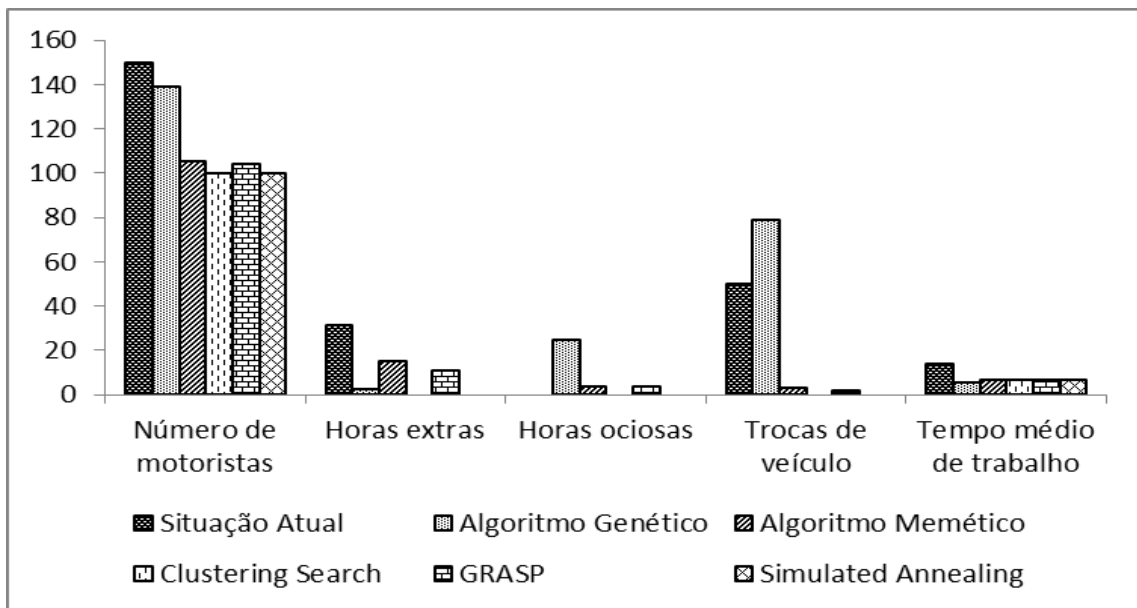


Figura 12. Comparação entre os melhores resultados no Cenário 5.

Analisando a Figura 12 é possível perceber que todos os métodos foram eficientes na resolução do problema, gerando soluções melhores do que a situação real, com exceção do AG que realizou mais trocas de veículos.

Comparando o AG, método que gerou os piores resultados, com a situação levantada na empresa (Tabela 17), fica evidente que mesmo não sendo o melhor, o AG conseguiu gerar resultados eficientes na redução dos custos operacionais. Esse método reduz em 11 unidades o quadro de motoristas, porém há um aumento nas horas extras de 01h03min para 02h23min. Já o número de horas que excedem as 12h foi eliminado e a jornada de trabalho para cada motorista foi reduzida para 05h15min

. Comparando o *Cluster Search* (CS), método que proporcionou os melhores resultados, com a situação levantada na empresa (Tabela 18), fica evidente que o CS reduz significativamente seus custos operacionais, amortizando em 50 unidades o quadro de motoristas e eliminando as horas extras e horas ociosas.

Tabela 17. Comparação entre valores observados e resultado da pior meta-heurística

	Situação Atual	Algoritmo Genético
Motorista	150	139
Jornada de trabalho (média diária)	13h52min	05h15min
Horas extras (média diária)	01h03min	02h23min
Horas excedentes (média diária)	00h51min	00h00min

Tabela 18. Comparação entre valores observados e resultado da melhor meta-heurística

	Situação Atual	Clustering Search
Motorista	150	100
Jornada de trabalho (média diária)	13h52min	06h55min
Horas extras (média diária)	01h03min	00h00min
Horas excedentes (média diária)	00h51min	00h00min

4.4. NOVA ESCALA DE SERVIÇOS

O CS permitiu a criação de uma nova escala de serviços para os motoristas no transporte de madeira. Um exemplo de parte dessa escala é apresentado na Tabela 19, que contém o código do motorista, os trechos de sua responsabilidade, o número do veículo utilizado, a qual grupo o motorista pertence, seu ponto de saída e chegada, assim como os horários de saída e chegada.

Tabela 19. Exemplo de escala de serviço

Motorista	Trecho	Veículo	Grupo	Ponto Inicial	Ponto Final	Hora Saída	Hora Chegada
1	37	10	1	Pátio	Ponto de Apoio	04h37min	07h53min
	38	10	1	Ponto de Apoio	Ponto de Apoio	07h53min	13h04min
51	113	25	4	Ponto de Apoio	Sapucaia	07h52min	08h32min
	114	25	4	Sapucaia	Pátio	08h32min	12h52min
	115	25	4	Pátio	Pátio	12h52min	13h34min
	116	25	4	Pátio	Sapucaia	13h34min	15h52min
59	197	45	5	Ponto de Apoio	Ponto de Apoio	05h06min	10h17min
70	190	43	5	Ponto de Apoio	Pátio	09h41min	14h41min
	191	43	5	Pátio	Pátio	14h41min	15h06min
	192	43	5	Pátio	Ponto de Apoio	15h06min	18h22min

Na situação levantada por esse estudo haverá, na escala diária de serviços, motoristas que atenderam somente um trecho enquanto outros poderão atender até quatro trechos. O motorista com o código 59 iniciará sua viagem no veículo 45 às 05h06min saindo do Ponto de Apoio e chegando ao Ponto de Apoio, após realizar o carregamento no campo, às 10h17min.

5. CONCLUSÕES

A empresa terceirizada responsável pelo transporte possui uma frota ativa de 50 CVC's e um quadro de 150 motoristas, trabalhando em turnos na escala 4 x 2. A carga horária diária dos motoristas é de 12h, e as médias de horas extras e horas excedentes são de 01h03min e 00h51min, respectivamente.

Foi possível verificar que o método CS obteve os melhores e mais consistentes resultados para todos os cenários, seguido pelo SA que gerou resultados próximos, porém com tempos computacionais ligeiramente melhores. O GRASP foi o método que apresentou resultados intermediários, baixos desvios, porém com tempo de execução elevado. Quanto ao AG e AM, estes apresentaram como métodos imprecisos devido aos altos desvios, piores resultados em relação aos outros métodos e tempo computacional também elevado.

Observa-se que mesmo o método que gerou os piores resultados (AG) dentre os outros, foi “melhor” que a situação atual da empresa, mostrando que o uso de métodos de otimização é uma maneira eficiente para melhor alocação dos recursos. O melhor método implementado (CS), em relação ao método utilizado na empresa, reduz, numa escala diária de serviços, em 1/3 o número de motoristas além de eliminar horas extras e excedentes trazendo consideráveis reduções na folha de pagamento da empresa.

A escala diária de serviços otimizada apresenta os trechos que os motoristas realizarão nas suas respectivas CVC's definindo o horário de saída e o provável horário de chegada em cada ponto.

6. REFERÊNCIAS

ANDRADE, E. L. de. **Introdução à pesquisa operacional: métodos e modelos para a análise de decisão**. 2. ed. Rio de Janeiro: LTC, 1998.

ANTONANGELO, A.; BACHA, C. J. C. As fases da silvicultura no Brasil. **Revista Brasileira de Economia**, São Paulo, v. 1, n. 52, p. 207-238, 1998.

ARCE, J. E. **Um sistema de programação do transporte principal de multiprodutos florestais visando a minimização de custos**. 1997. 98 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba-PR.

ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS. **Anual Estatístico ABRAF 2011, ano base 2010**. Brasília, 2011. Disponível em: <<http://www.abraflor.org.br/estatisticas/ABRAF11/ABRAF11-BR.pdf>>. Acesso em: 20 de maio de 2011.

BARNES, R. M. **Estudo de movimentos e de tempos: projeto e medida do trabalho**. 6. ed. São Paulo: Edgar Blücher, 1977. 648 p.

BARTON, D.; HAMILTON, M. **Local literacies: reading and writing in one community**. New York: Routledge, 1998. 229 p.

BERGER, R.; TIMOFEICZYK JR, R.; CARNIERI, C.; LACOWICZ, P. G.; SAWINSKI JR, J.; BRASIL, A. A. Minimização de custos de transporte florestal com a utilização da programação linear. **Revista Floresta**, Curitiba, v. 33, n. 1, p. 33-50, 2003.

BINOTI, D. H. B. **Estratégias de regulação de florestas equiâneas com vistas ao manejo da paisagem**. 2010. 145 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Viçosa, Viçosa-MG.

CHAVES, A. A. **Otimização combinatória**. 2007a. Disponível em: <http://www.lac.inpe.br/~lorena/cap/Aula_C05.pdf>. Acesso em: 20 de dezembro 2011.

CHAVES, A. A. **Otimização combinatória**. 2007b. Disponível em: <http://www.lac.inpe.br/~lorena/cap/Aula_C01.pdf>. Acesso em: 20 de dezembro 2011.

CHAVES, A. A. **Uma meta-heurísticas híbrida com busca por agrupamentos aplicada a problemas de otimização combinatória**. 2009. 197 p. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos – SP.

COELHO, A. M. **Uma abordagem via algoritmos meméticos para solução do problema de horário escolar**. 2006. 115 p. Dissertação (Mestrado em

Modelagem Matemática e Computacional) – Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte – MG.

CRABTREE, B. F.; MILLER, W. L. **Doing qualitative research in primary care: multiple strategies**. London: Sage Pubns., 1992. 272 p.

DAWKINS, R. **The selfish gene**. New York: Oxford Univ. Pr. 1976. 360 p.

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

GOLDBARG, M. C.; LUNA, H. P. L. **Otimização combinatória e programação linear**. 2. ed. Rio de Janeiro: Elsevier, 2005. 511 p.

GOLDBERG, D. E. **Genetic algorithms in search, optimization and machine learning**. Boston: Addison- Wesley Longman Publishing Co, 1989. 372 p.

HAMMERSLEY, M. **Introducing ethnography**. In: GRADDOL, D. et al. editores, RESEARCHING LANGUAGE AND LITERACY IN SOCIAL CONTEXT. Clevedon: Multilingual Matters, The Open University, 1994. p. 1-17.

HOLLAND, J. H. **Adaptation in natural and artificial systems**. Ann Arbor: University of Michigan Press, 1975. 183 p.

KARP, R. **Reducibility Among Combinatorial Problems**. In: MILLERT, R. e THATCHER, J., editores, COMPLEXITY OF COMPUTER COMPUTATIONS, p. 85 – 103. Plenum Press, 1972.

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

LACHTERMACHER, G. **Pesquisa operacional na tomada de decisões: modelagem em Excel**. 3 ed. Rio de Janeiro: Campus Elsevier, 2006. 224 p.

LACOWICZ, P. G.; BERGER, R.; TIMOFEICZYK JUNIOR, R.; SILVA, J. C. G. L. Minimização dos custos de transporte rodoviário florestal com o uso da programação linear e otimização do processo. **Floresta**, Curitiba, v. 32, n. 1, p.75-87, fev. 2002.

LEÃO, R. M. **A floresta e o homem**. São Paulo: Endusp, 2000. 448 p.

LEITE, J. M. **A otimização dos custos do transporte rodoviário de madeira roliça oriunda de reflorestamento**. 2002. 273 p. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba-PR.

LOPES, E. S. **Estudo de tempos e movimentos aplicados na colheita e transporte florestal**. 2010. 14 f. Notas de aula.

LUCAS, D. C. **Algoritmos genéticos**: uma introdução. 2002. Disponível em: <<http://www.inf.ufrgs.br/~alvares/INF01048IA/ApostilaAlgoritmosGeneticos.pdf>>. Acesso em: 21 de dezembro de 2011.

MAANEN, J. V. *Reclaiming qualitative methods for organizational research: a preface*. In: **Administrative Science Quarterly**, vol. 24, n. 4, 1979, p 520-526.

MACHADO, C. C.; LOPES, E. S.; BIRRO, M. H. B.; MACHADO, R. R. **Transporte rodoviário florestal**. 2. ed. Viçosa: Editora UFV, 2009. 217 p.

MAURI, G. R. **Novas abordagens para representação e obtenção de limitantes e soluções para alguns problemas de otimização combinatória**. 2008. 239 p. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos-SP.

MAURI, G. R. **Novas heurísticas para o problema de escalonamento de tripulações**. 2005. 103 f. Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos-SP.

MAURI, G. R. **Unidade IV: Simulated annealing**, 2011. Disponível em: <<http://www.grmauri.pro.br/disciplinas.html>>. Acesso em: 20 de dezembro de 2011.

MAXIMIANO, A. C. A. **Teoria geral da administração**: da revolução urbana à revolução digital. São Paulo: Atlas, 2002. 500 p.

MELÍAN, B.; PÉREZ, J. A. M.; VEJA, J. M. M. Metaheuristics: a global view. **Revista Iberoamericana de Inteligencia Artificial**, n. 19, p. 7-28, 2003.

MÉLLO, F. G. A.; SENNE, E. L. F.; LORENA, L. A. N. **Uma Abordagem para Solução do Problema de Escalonamento de Motoristas**. *Revista Produto & Produção*. 2009. Disponível em: <<http://seer.ufrgs.br/ProdutoProducao/article/view/1477>>. Acesso em 12 de maio de 2011.

MNWS, 2011 - Metaheuristics Network Web Site. Disponível em <<http://www.metaheuristics.net>>. Acesso: 20 de dezembro de 2011.

MOSCATO, P. **On evolution, search, optimization, genetic algorithms and martial arts**: towards memetic algorithms. Tech. Rep. Caltech Concurrent Computation Program, Report. 826, California Institute of Technology, Pasadena, California, USA, 1989.

OLIVEIRA, A. C. M. **Algoritmos evolutivos híbridos com detecção de regiões promissoras em espaços de busca contínuo e discreto**. 2004. 79 p. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos-SP.

PAREDES, G.; SESSIONS, J. A solution method for the transfer yard location problem. **Forest Products Journal**, Madison, v. 38, n. 3, p. 53-58, mar. 1988.

RAIDL, G. L. A unified view on hybrid metaheuristics. **Lecture Notes in Computer Science, Book: Hybrid Metaheuristics**, vol. 4030, p. 1-12, 2006.

RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. N.; SOUZA, A. L. de; RIBEIRO, C. A. A. S. Metaheurística *Simulated annealing* para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, Viçosa, v. 28, n. 2, p. 247-256, mai. 2004.

RODRIGUES, P. **Introdução aos sistemas de transporte no Brasil e à logística internacional**. 4. Edição revisão e ampliada. Aduaneiras, 2007.

RONEN, D. Perspectives on practical aspects of trucks routing and scheduling. **European Journal of Operational Research**, v. 35, p. 137-145, mai. 1988.

SEIXAS, F.; WIDMER, J. A. Seleção e dimensionamento da frota de veículos rodoviários para o transporte principal de madeira, utilizando-se de programação linear não-inteira. **Scientia Forestalis**, Piracicaba, n. 46, p. 107-118, jan./dez. 1993.

SIMÕES, D. **Avaliação econômica de dois sistemas de colheita florestal mecanizada de eucalipto**. 2008. 105 f. Dissertação (Mestrado em Agronomia) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu-SP.

SOARES, N. S.; SOUSA, E. P.; SILVA, M. L. Importância do setor florestal para a economia brasileira. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA, ADMINISTRAÇÃO E SOCIOLOGIA RURAL, 46., 2008, Rio Branco. **Anais eletrônicos...** Rio Branco: SOBER, 2008. Palestra. Disponível em: <<http://www.sober.org.br/palestra/9/214.pdf>>. Acesso em: 23 de mai. de 2011.

SOUZA, R. A. T. M. e; RODRIGUEZ, L. C. E.; SEIXAS, F.; CAIXETA FILHO, J. V. Eficiência e otimização do transporte principal de toras curtas de eucalipto. **Scientia Forestalis**, Piracicaba, n. 62, p. 130-146, dez. 2002.

SUCUPIRA, I. R. **Métodos heurísticos genéricos: metaheurística e hiper-heurísticas**. 2004 41 p. Monografia (Ciência da Computação) – Universidade de São Paulo, São Paulo-SP.