

T 634.92

NOB
heu

SILVANA RIBEIRO NOBRE

**A HEURÍSTICA DA RAZÃO-R
APLICADA A PROBLEMAS DE GESTÃO FLORESTAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Mestrado em Administração Rural, área de concentração em Administração da Empresa Rural, para obtenção do título de "Mestre".

Orientador

Prof. Luiz Carlos Estraviz Rodriguez

**LAVRAS
MINAS GERAIS – BRASIL
1999**

**CENTRO de DOCUMENTAÇÃO
CEDOC/DAE/UFLA**

**Ficha Catalográfica Preparada pela Divisão de Processos Técnicos da
Biblioteca Central da UFLA**

Nobre, Silvana Ribeiro

**A heurística da razão-R aplicada a problemas de gestão florestal / Silvana Ribeiro
Nobre. – Lavras : UFLA, 1999.**

129 p. : il.

Orientador: Luiz Carlos Esteviz Rodriguez.

Dissertação (Mestrado) – UFLA.

Bibliografia.

1. Manejo florestal. 2. Planejamento. 3. Heurística. 4. Razão-r. 5. Administração rural. 6. Inteligência artificial. 7. Programa de computador. I. Universidade Federal de Lavras. II. Título

**CDD-634.92
-630.68**

SILVANA RIBEIRO NOBRE

**A HEURÍSTICA DA RAZÃO-R
APLICADA A PROBLEMAS DE GESTÃO FLORESTAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Mestrado em Administração Rural, área de concentração em Administração da Empresa Rural, para obtenção do título de “Mestre”.

Aprovada em 21 de setembro de 1999

Prof. Ricardo Pereira Reis (co-orientador) UFLA

Prof. Heleno do Nascimento Santos UFV

Prof. Antônio Carlos dos Santos UFLA



Prof. Luiz Carlos Estraviz Rodriguez

ESALQ-USP

(Orientador)

**LAVRAS
MINAS GERAIS – BRASIL**

Aos amados co-autores: Eduardo, Miriam e Luísa

AGRADECIMENTOS

À Universidade Federal de Lavras, pelo que me acrescentou durante as disciplinas do mestrado e à Universidade de São Paulo – ESALQ, pelo apoio com infra-estrutura para realização dos trabalhos.

À CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pelo apoio financeiro.

Aos amigos Mauro e Eduardo da Athena Consultoria e Sistemas, pelo indispensável apoio tecnológico, sugestões, críticas à implementação da heurística.

Aos meus pais e a Lelena, minha irmã, que me apoiaram e incentivaram. À minha mãe, que cuidou das minhas filhas durante os períodos mais apertados.

Ao casal Renata e Vicente von Glehn pelo carinho e atenção que me dispensaram nas muitas vezes que me hospedaram em sua casa.

Aos professores, funcionários e colegas do Departamento de Administração e Economia da Universidade Federal de Lavras.

Aos amigos que ajudaram e colaboram de alguma forma para que esse trabalho fosse possível: Rodolfo e Prof. Tadeu, Mário e Ângela, Leonardo e Maria Tereza, Adriana, Raquel e Nelson, Bete, Lucília, Prof. Manoel, Prof. Heleno, Nilza, Joel e Rute, e aos que, infelizmente, esqueci.

Especialmente, ao amigo Luiz Carlos que, com paciência, carinho e dedicação me ensinou, ajudou e orientou durante esses especiais dois anos e meio de convivência.

E a todas essas pessoas, também porque

*“...aprendi que se depende sempre
de tanta muita diferente gente,
toda pessoa sempre é as marcas
das lições diárias de outras tantas pessoas...” (Gonzaguinha)*

SUMÁRIO

RESUMO.....	1
ABSTRACT.....	2
INTRODUÇÃO.....	3
1 PLANEJAMENTO GERENCIAL DA PRODUÇÃO	6
1.1 Etapas funcionais, etapas da administração e níveis de decisão.....	6
1.2 A evolução da lógica do planejamento.....	7
1.3 Planejamento otimizado e sistema de informações	11
1.4 Gestão Florestal e Planejamento Otimizado.....	14
2 IMPORTÂNCIA DO PLANEJAMENTO PARA A INDÚSTRIA DE BASE FLORESTAL	18
2.1 Setores que utilizam a madeira como matéria-prima.	18
2.2 Tendência de crescimento da demanda dos produtos que utilizam madeira	20
2.3 Complexidade das decisões do gestor florestal.	23
3 MODELOS DE OTIMIZAÇÃO DO PLANEJAMENTO FLORESTAL	27
3.1 Uso da Programação Matemática.....	27
3.2 Propostas heurísticas para a solução de problemas de grande porte	29
3.3 A heurística da Razão-R para problemas de programação inteira.....	33
4 DESCRIÇÃO E ANÁLISE DA HEURÍSTICA DA RAZÃO-R.....	36
4.1 Descrição da Heurística da Razão R	36
4.2 Inteligência Artificial e Busca Heurística.....	40
4.2.1 Sistemas de inteligência artificial.....	41
4.2.2 Estados e Movimentos.....	43
4.2.3 Informações heurísticas.....	46
4.2.4 Estratégias de controle e técnicas de busca heurística.....	47
4.3 Técnicas heurísticas para modelos de programação inteira.....	48

4.4	Abordagem moderna de inteligência artificial: agentes inteligentes.....	49
4.4.1	O agente que busca atingir metas	50
4.4.3	Buscas heurísticas	54
4.5	Algoritmos Iterativos de Melhoria	59
4.5	Conclusões da análise da Razão-R.....	62
5	AVALIAÇÃO DO DESEMPENHO DA NOVA HEURÍSTICA DA RAZÃO- R	64
5.1	Análise do desempenho.....	64
5.1.1	Os elementos avaliados	64
5.1.2	Medidas de desempenho	67
5.1.3	Problemas usados nos testes.....	69
5.1.4	Metodologia dos testes	71
5.2	Resultados e discussão da avaliação de desempenho.....	72
	CONCLUSÕES E CONSIDERAÇÕES FINAIS	88
	BIBLIOGRAFIA.....	92
	ANEXOS	99

RESUMO

NOBRE, Silvana Ribeiro. A heurística da Razão-R aplicada a problemas de gestão florestal. Lavras: UFLA, 1999. 129p. (Dissertação – Mestrado em Administração Rural)

A heurística da Razão-R, proposta para solucionar o problema de planejamento florestal de larga escala envolvendo grande número de variáveis de decisão, foi analisada e confrontada com os princípios da Inteligência Artificial. A heurística, analisada sob todos os aspectos relevantes propostos pela teoria de construção de buscas heurísticas, mostrou-se promissora por vários motivos, mas principalmente pela simplicidade e consistência de sua lógica. A utilização de princípios da Inteligência Artificial induziu também a introdução de algumas modificações. Essas melhorias foram testadas em problemas que já haviam sido solucionados por versões anteriores da heurística permitindo comparações. Verificou-se o efeito das melhorias sobre a eficiência, eficácia e tempo computacional. Constatou-se que a Razão-R melhorou a sua eficácia para todos as dimensões de problemas testados e o tempo computacional diminuiu cerca de 40 vezes. A eficiência, medida com o auxílio de conceitos propostos pela teoria de buscas heurísticas, mostrou que a Razão-R é bastante eficiente mesmo para grandes problemas. Foram testadas estratégias de fuga de ótimos locais e definidos os respectivos intervalos mais eficientes para os parâmetros da heurística. Investigaram-se critérios de interrupção da busca para estratégias menos produtivas evitando iterações desnecessárias. E, finalmente, os resultados foram discutidos à luz da lógica de construção da Razão-R e dos princípios de Inteligência Artificial, que justificam as melhorias e o bom desempenho da heurística.

Orientador: Prof. PhD Luiz Carlos Estraviz Rodriguez – ESALQ – USP.
Co-orientador: Prof. PhD Ricardo Pereira Reis – UFLA.

ABSTRACT

NOBRE, Silvana Ribeiro. The R-ratio heuristic applied to forest management problems. Lavras: UFLA, 1999. 129p. (Dissertation – Master in Rural Administration)

The R-ratio heuristic method for solving large scale forest planning problems was analyzed according to Artificial Intelligence principles. The method is promising if considered all relevant aspects related to the construction of efficient searches, mainly due to its simplicity and consistent logic. The analysis based on Artificial Intelligence introduced some changes to the original implementation. These improvements were tested in problems previously solved by older versions of the heuristic, allowing further comparisons. The improvements were evaluated based on efficiency, efficacy and computational time. Results show that efficiency improved for all problem dimensions and time was reduced about 40 times. The efficiency, measured by concepts derived from heuristic search testing criteria, reveals that the R-ratio heuristic is very efficient even for large problems. Local optimum escape strategies were tested and the respective efficient intervals for the heuristic parameters were also defined. Interruption criteria of the search for less productive strategies were investigated. And finally, the results were discussed under the R-ratio building logic and the Artificial Intelligence assumptions, that justify the good performance of the heuristic.

Adviser: Prof. PhD. Luiz Carlos Estraviz Rodriguez – ESALQ – USP.
Co-adviser: Prof. PhD. Ricardo Pereira Reis – UFLA

INTRODUÇÃO

O manejo florestal, sob o enfoque da gestão administrativa, envolve atividades relacionados com planejamento, organização, comando, coordenação e controle (definidas por Henri Fayol, segundo Bateman e Snell, 1998). Se orientado principalmente para o planejamento, o manejo florestal define-se melhor como uma atividade de administração quantitativa, fortemente baseada em técnicas de otimização matemática e de pesquisa operacional.

O recurso a essas técnicas é explicado pela própria natureza do problema básico de manejo florestal, que procura elaborar um plano especificando as diversas intervenções silviculturais que atendem às demandas e restrições definidas para um certo período de tempo. Essas intervenções, incluindo colheitas e plantios, devem necessariamente atender às limitações operacionais e resultar em um fluxo adequado e sustentável de produção.

O equacionamento do problema envolve a definição de um número muito grande de alternativas silviculturais para cada unidade de manejo na floresta. Dentre essas, e para cada unidade, o gestor deve escolher a que melhor atende aos seus objetivos e restrições operacionais. O problema resultante pode se tornar de difícil solução principalmente devido ao grande número de variáveis envolvidas, e à natureza combinatorial do problema quando impostas restrições espaciais e de integridade das unidades de manejo.

As abordagens tradicionais envolvendo o uso da programação matemática têm oferecido bons resultados para problemas de pequena dimensão. Para o tratamento dos problemas de grande porte, comuns quando da análise de situações reais, maior sucesso tem sido obtido com o uso de métodos heurísticos. Uma das heurísticas com maior potencial foi desenvolvida por Rodriguez (1994) e denominada Razão-R. Procura-se neste trabalho desenvolver e avaliar a

contribuição desta heurística como técnica de solução do problema básico de gestão florestal.

Mais especificamente, os objetivos deste trabalho podem ser resumidos da seguinte forma:

- *Caracterizar a lógica que torna a Razão-R uma heurística promissora*
A hipótese ou pressuposição que se procura evidenciar neste trabalho é a de que o algoritmo da Razão-R segue os conceitos de *busca heurística* definidos pelos princípios de Inteligência Artificial.
- *Avaliar a introdução de melhorias no desempenho da heurística da Razão-R*
Associado a este objetivo geral, destacam-se cinco objetivos específicos:
 - *Avaliar o ganho na velocidade computacional da heurística*
O que se procura, nesse caso, é comprovar que alterações na base de representação dos dados tornam o processamento mais rápido.
 - *Consolidar as estratégias de fuga de ótimos locais*
A heurística da Razão-R se baseia em parâmetros que alteram a estratégia de busca da melhor solução. Este trabalho procura evidenciar que o uso de grandes intervalos de variação para esses parâmetros proporcionam as condições necessárias para a fuga de ótimos locais.
 - *Avaliar a eficiência da heurística*
Através de medidas de eficiência sugeridas pelos princípios de Inteligência Artificial, serão apresentados resultados para problemas de diferentes dimensões que comprovem a boa qualidade da heurística.
 - *Avaliar o efeito das melhorias sobre a eficácia da heurística*
Procura-se, neste caso, comparar os resultados obtidos para problemas de diferentes dimensões e levantar evidências que comprovem a boa qualidade das soluções apresentadas pela heurística.
 - *Propor formas de redução de iterações desnecessárias*
São apresentadas evidências de que a heurística poderia se basear em

indicadores, calculados durante o processamento, para sinalizar a necessidade ou não de interrupção do processamento, evitando com isto a continuidade de uma estratégia de busca improdutiva.

As próximas seções estão organizadas em cinco capítulos. O primeiro capítulo enquadra o problema básico da gestão florestal como uma tarefa de planejamento gerencial da produção e justifica, devido ao seu alto grau de complexidade, a necessidade do uso de soluções baseadas em tecnologia de informação. O segundo capítulo detalha a importância do problema e descreve os setores que têm a madeira como matéria-prima no Brasil. O terceiro capítulo apresenta uma revisão de literatura sobre as soluções que as pesquisas têm apresentado para o problema básico de gestão florestal, dando ênfase à utilização da programação matemática, de heurísticas e de modelos de programação inteira, nos quais se baseia a heurística da Razão-R. O quarto capítulo se concentra no atendimento do primeiro objetivo geral, contrapondo a heurística da Razão-R aos conceitos da Inteligência Artificial. O quinto capítulo descreve e apresenta as evidências que permitem corroborar as pressuposições apresentadas para o segundo objetivo geral. As conclusões são apresentadas e discutidas em uma seção final. O enfoque principal dessa seção é inferir sobre as hipóteses e pressuposições propostas juntamente com os objetivos.

1 PLANEJAMENTO GERENCIAL DA PRODUÇÃO

1.1 Etapas funcionais, etapas da administração e níveis de decisão

Vários autores, para maior compreensão de uma organização, dividem suas áreas funcionais em: produção, recursos humanos, finanças e marketing (Andrade, 1995). A área de produção se relaciona com a utilização dos recursos materiais necessários à operação da empresa. Todos os conceitos de quantidade produzida, produtividade, qualidade e custos estão relacionados com a produção. Quanto ao processo administrativo, a organização é composta por quatro etapas: planejamento, organização, direção e controle. Planejar é decidir o que deve ser feito antecipadamente levando em conta os objetivos e as condições da organização. Existem também três níveis de decisão: o estratégico, o gerencial e o operacional. No nível estratégico definem-se os objetivos, no nível gerencial define-se como fazer para atingi-los, e no nível operacional executam-se as tarefas definidas pelo nível gerencial.

Analisando tais áreas funcionais, etapas da administração e níveis de decisão, verificamos que o que se propõe neste trabalho é a solução de um problema de produção, no nível de decisão gerencial da etapa de planejamento.

O planejamento da produção é a função administrativa que tem por objetivo fazer os planos que orientam a produção. Procura determinar o que, quanto, como, onde produzir. Enquanto que o planejamento gerencial da produção é um subconjunto das funções do planejamento da produção, que se preocupa com o processo de tomada de decisão, e que seleciona, dentre várias alternativas disponíveis, um determinado curso de ação. (Guimarães e Sette, 1995).

“O planejamento gerencial está intimamente relacionado com o processo decisório... envolve um diagnóstico do problema, a procura de

soluções alternativas, análise e solução das prováveis soluções, e finalmente a seleção e escolha da melhor alternativa” (Guimarães e Sette, 1995, p.22)

Para Corrêa et al. (1997) o planejamento da produção deve ser contínuo e é uma tarefa que levanta e trata a situação presente, e deduz o que se quer no futuro.

Moreira (1996) conceitua planejamento gerencial da produção como uma atividade que dá a base para as outras atividades gerenciais futuras, na medida em que estabelece linhas de ação que devem ser seguidas para que os objetivos sejam alcançados.

A ciência da administração, entretanto, tem caminhado na direção da integração entre as áreas da empresa e tem mostrado a necessidade de que todas as etapas sejam feitas em conjunto (Kotler, 1998). Entretanto, dentre as principais etapas, o planejamento tem sido considerado a base para as demais.

Drucker (1995) afirma que a maioria das soluções comerciais de software é construída para apoiar o nível operacional. Poderíamos concluir, portanto, que existe uma demanda reprimida nos níveis gerenciais e estratégicos. O presente trabalho visa preencher uma lacuna no nível de decisão relativo ao planejamento gerencial nas organizações que se ocupam da produção florestal.

1.2 A evolução da lógica do planejamento

A tomada de decisão da qual se ocupa o planejamento da produção envolve uma situação problema, em que o gerente se depara com várias alternativas de solução (Moreira, 1996). Em geral existem muitas soluções, dentre as quais selecionam-se as viáveis, e dentre estas a melhor. Estas soluções são construídas a partir de informações do problema. A partir do estudo e análise das informações, o gerente, em geral, constrói modelos de decisão.

A modelagem envolve o processo de transformar as informações de um

problema e organizá-las formalmente de acordo com princípios lógicos e matemáticos (Moreira, 1996). Esse processo é crítico na tomada de decisão pois o modelo gerado nessa fase determina a forma como o gerente vê o problema e a própria representação da realidade.

Os modelos mais comuns utilizados pela indústria, serviços e agricultura são baseados em princípios de probabilidade, programação matemática, PERT/CPM, análise de regressão, e simulação. Os modernos modelos construídos para representar a complexidade da realidade exigem a utilização de computadores.

Historicamente, o planejamento da produção tem se baseado no conceito do cálculo das necessidades de materiais: se são conhecidos todos os componentes de determinado produto e os tempos de obtenção de cada um deles, pode-se calcular os momentos e as quantidades que devem ser obtidos para cada um dos componentes de um produto.

Esse conceito evoluiu de tal forma na indústria, principalmente na manufatura, que deu origem a grandes sistemas de planejamento da produção baseados na lógica do cálculo das necessidades. As grandes indústrias e manufaturas, desde a revolução industrial, sistematizaram esse conceito de planejamento criando grandes sistemas com duas características importantes:

- cálculo das necessidades partindo do futuro para trás
- consideração das capacidades de produção infinitas

O sistema de produção que se baseia nessa lógica se chama MRP (material requirements planning). Na última década o MRP se ampliou e não se preocupa somente com o cálculo das necessidades de materiais, mas também com todas as necessidades da produção: pessoal e capacidade de máquinas, e por isso tem sido chamado de MRP II (manufacturing resources planning), sendo o que mais tem sido implantado na manufatura (Corrêa e Gianesi, 1993).

Nas últimas décadas, esse sistema de planejar a produção serviu de base

para o desenvolvimento de softwares que têm sido muito utilizados pela indústria nacional e internacional (Corrêa e Gianesi, 1993).

O cálculo envolve capacidade infinita de produção. Para contornar essa imposição metodológica o MRP II tem módulos que verificam a viabilidade do plano de produção gerado pelo módulo de cálculo (Layden 1996).

Os módulos de cálculo e de verificação trabalham sobre a mesma base de dados e o usuário trabalha utilizando a técnica da tentativa e erro, planejando, verificando e replanejando. O que se observa, portanto, é que o gerente se baseia nas informações para encontrar uma solução, e depois verifica se a solução é viável se sujeita às limitações de capacidade. Como essa técnica de busca da melhor solução dentre as viáveis tende a ser infundável, é comum que o gerente se contente em escolher a primeira solução factível que aparecer.

O MRP II ampliou sua área de atuação dentro das organizações e fundiu-se com os sistemas administrativos, dando origem aos softwares de gestão empresarial. Estes grandes sistemas que pretendem controlar e planejar toda a empresa são chamados de ERP (enterprise resources planning). Estes sistemas representaram um mercado de 10 bilhões de dólares em 1997, que é dominado pela gigante alemã SAP, seguida da BAAN, Oracle e outros grandes e pequenos grupos americanos e europeus.

A lógica do MRP, com o seu cálculo para trás baseado na capacidade infinita, tem dominado e persistido como meio de planejar a produção (Gumaer, 1996 ; Layden 1996).

Da mesma forma que o cenário tecnológico favoreceu o desenvolvimento dos sistemas baseados no MRP II, favoreceu também o desenvolvimento das tecnologias de *scheduling*. O *scheduling*, ou programação da produção, se preocupa com as decisões de curto prazo. Nas indústrias - manufaturas e outras - essas são decisões de como atender aos pedidos em carteira, em que ordem, como arranjar as máquinas etc. (Green, 1996 e Salegna,

1996).

Mas “as decisões decorrentes da programação da produção tornam-se um problema combinatório de tal ordem que soluções intuitivas são inadequadas pelas limitações humanas de administrar informações” (Corrêa et al., 1997). Nesse contexto, surgem os sistemas de administração da produção com capacidade finita, que consideraram “a capacidade produtiva e as características tecnológicas do sistema produtivo como restrições *a priori* para a tomada de decisão de programação, buscando garantir que o programa de produção resultante seja viável” (Corrêa et al., 1997). No contexto desta dissertação chamaremos este planejamento de “planejamento otimizado”.

Inserida na tecnologia de informação desenvolvida nas últimas décadas, e apoiando os modelos de *scheduling*, está a Pesquisa Operacional que vem se estabelecendo como ciência básica de apoio à tomada de decisão. A sua utilização muito se difundiu com o desenvolvimento dos computadores, que permitiram a implementação de eficientes algoritmos de solução dos principais problemas tratados pela Pesquisa Operacional.

Os sistemas de produção com capacidade finita podem ser agrupados da seguinte forma:

- Baseados em regras de liberação - são os mais difundidos pela facilidade da modelagem, apesar de Corrêa et al. (1997) afirmar que as soluções são “relativamente pobres”.
- Matemáticos otimizantes - muito difundidos, mas que podem se mostrar limitados se usados para resolver problemas de grande porte.
- Matemáticos heurísticos - aplicados em problemas para os quais não existem métodos de otimização matemática eficientes. Produzem resultados melhores do que os métodos baseados em regras de liberação mas podem ser complexos dado o grau de sofisticação computacional necessária.

- Sistemas especialistas puros - baseados em regras de decisão e bases de conhecimentos.
- Redes neurais - com pesquisas ainda limitadas ao campo acadêmico.

Vários autores apontam o OPT (*optimized production technology*) como o mais utilizado comercialmente dentre os sistemas que consideram as restrições da produção. É um sistema matemático heurístico (Corrêa e Giansi, 1993) e tem suas bases na Teoria das Restrições de Goldratt. Corrêa et al. (1997) dizem que as heurísticas “utilizam algoritmos de busca desenvolvidos segundo o conceito da inteligência artificial - e métodos baseados em gargalos, predominantemente derivados da teoria das restrições”.

A teoria das restrições foi criada por Goldratt e sua teoria é apresentada no livro “A Meta”, e foi um marco importante para a administração da produção, sobretudo nas técnicas de planejamento da produção. A heurística decide em que ordem executar as ordens de serviço e como arranjar os recursos produtivos para tal (Green, 1996).

1.3 Planejamento otimizado e sistema de informações

A informação é um dos recursos vitais da empresa, pois é a base para a tomada de decisão. A informação compreende dados trabalhados ou analisados (Oliveira, 1993). Informação gerencial é a que pode ser usada com objetivos gerenciais, ou seja para planejar, controlar, dirigir ou organizar uma empresa. Para Oliveira (1993), sistema de informações gerenciais é o processo de transformação de dados em informações que são utilizadas na estrutura decisória da empresa. O sistema de informações gerenciais de uma empresa está inserido numa rede de informações globais da empresa. O que quer dizer que apenas parte das informações da empresa são gerenciais. Esse sistema pode ser informatizado ou não, e, ainda, formal ou informal.

Um sistema de informações gerenciais tem como objetivo a geração de

informação base para decisões ou o fornecimento de elementos básicos para a decisão. Evolui-se, então, para o conceito de sistema de apoio à decisão que se propõe a ser flexível e ágil, apoiando-se em métodos da pesquisa operacional (Oliveira, 1993).

Segundo Silva Jr (1993), um sistema de suporte à decisão auxilia, mas não substitui, os especialistas humanos. Sua principal característica é a possibilidade de testar, de maneira rápida e objetiva, diferentes estratégias dentre um conjunto de alternativas de ação.

Campos Filho (1994) amplia o conceito de sistema de informações e vai além do conceito de sistema para suporte a decisão quando define sistema de informação como uma combinação estruturada de informação, recursos humanos, tecnologia de informação e práticas de trabalho, organizados de forma a permitir o melhor atendimento dos objetivos da organização (Figura 1).

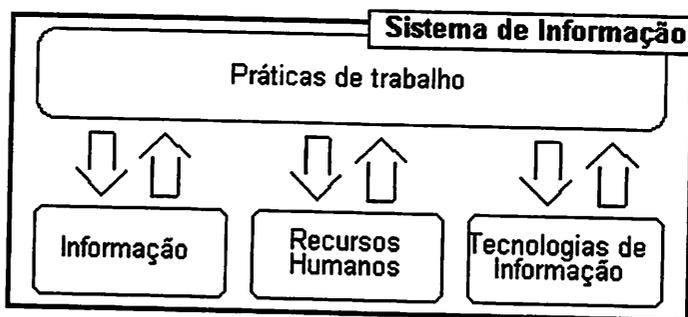


FIGURA 1 Sistema de Informação

O papel dos recursos humanos em um sistema de informações se materializa através das *práticas de trabalho*. Essas práticas resultam em rotinas, e a forma como essas rotinas se comunicam, usam as informações e se organizam para servirem de suporte à decisão é alvo do interesse de especialistas em sistemas de informação.

Em resumo, um sistema de informação é constituído basicamente (i) pela informação, definida como sendo um conjunto de dados organizados de forma a

servirem a um fim específico (Drucker, 1995 e Campos Filho, 1994), (ii) pelos recursos humanos envolvidos no sistema de informação, isto é, pelas pessoas que realizam as *práticas de trabalho* dentro do sistema, e (iii) pela tecnologia presente no hardware e software utilizados pelo sistema de informação.

Campos Filho (1994) afirma que as empresas devem estar atentas para todos os componentes de um sistema de informação. De acordo com esse autor, as empresas que não vêem o sistema de informação como um produto desses componentes correm o risco de não conseguirem administrar seus sistemas corretamente. O mesmo autor afirma que o ponto crucial do gerenciamento de um sistema de informação está em como os componentes interagem para criar práticas de trabalho que atendam aos objetivos da organização. Uma das causas mais frequentes de insucesso de um sistema de informação está na tendência de supervalorizar as tecnologias em detrimento das práticas de trabalho.

A tecnologia, por sua vez, capacita as práticas de trabalho e são o ponto de partida para as inovações necessárias à sobrevivência das organizações. Novas tecnologias abrem possibilidades de avanço nas práticas de trabalho, e permitem aos gestores trabalhar de forma inovadora (Campos Filho, 1994). A este fato soma-se a constatação de Gonçalves (1998): “*A tecnologia é o fator individual de mudança de maior importância na transformação das empresas*”.

Na conceituação de sistema de informação já se percebem algumas características desejáveis da tecnologia: agilidade, flexibilidade, foco nas informações úteis à tomada de decisão.

Além dessas características, óbvias na construção de qualquer software, Silva (1998) chama a atenção para a interatividade. Deve-se buscar tirar proveito da oportunidade que as ferramentas de desenvolvimento de software dão aos desenvolvedores. A popularização do computador pessoal, e, ainda mais recentemente, dos ambientes visuais em *janelas*, envolve as pessoas no processo tecnológico que o próprio software oferece.

Assim, utilizando os conceitos de Campos Filho (1994), Silva (1998) e Gonçalves (1998), a tecnologia deve ser construída para ser inserida em um sistema de informação de forma a permitir uma maior interação, natural e segura, entre os recursos humanos e a tecnologia.

1.4 Gestão Florestal e Planejamento Otimizado

A *gestão florestal* preocupa-se com o processo de tomada de decisões relativas à organização, uso e conservação de recursos florestais. Tais decisões podem ser de longo prazo ou de curto prazo, e resultam em recomendações denominadas planos de *manejo florestal*. A programação (*scheduling*) da colheita ao longo dos períodos futuros é uma das numerosas tarefas do gestor florestal (Buongiorno e Gillies, 1987; Leuschner, 1984).

Segundo Scolforo (1997), o *manejo florestal* envolve o conceito da utilização de forma sensata e sustentada dos recursos florestais, e a função básica do manejo florestal é conduzir o recurso florestal para atender aos objetivos de uma organização. O gestor florestal gerencia uma grande gama de informações, necessárias para a análise e seleção do melhor plano de manejo possível, que por sua vez é selecionado dentre as alternativas de produção disponíveis.

Para Paivinen (1996) a tarefa do gestor florestal é descrever o potencial de produção de uma floresta determinando quando, onde e quais produtos e serviços serão produzidos para as diversas unidades florestais .

Rodriguez (1996) conceitua gestão florestal como sendo o estudo, desenvolvimento e aplicação de técnicas que ajudam a justificar a escolha de um determinado plano de manejo. O plano de manejo nesse contexto define a condução da floresta, e envolve conhecimentos silviculturais relativos à escolha de espécies, espaçamentos, manutenções, desbastes e podas (Scolforo, 1997), assim como o domínio de técnicas matemáticas e estatísticas de modelagem do crescimento da floresta e do problema de definição do momento ideal de corte.

O processo de gestão florestal, dependendo da abrangência do seu enfoque, pode se ater à gestão por talhões ou à gestão para a floresta.

O objetivo da gestão por talhões é “otimizar o crescimento, a produção de biomassa ou o resultado econômico líquido da exploração de cada ciclo florestal em cada talhão florestal” (Rodriguez, 1999).

O objetivo da gestão para a floresta visa a gestão sustentável do recurso florestal e para isso considera simultaneamente todos os talhões florestais (Rodriguez, 1999). Desta forma, a gestão para a floresta implica na otimização do manejo simultâneo de todos os talhões que constituem a floresta. A gestão para a floresta pode ocorrer em um nível tático ou estratégico (Rodriguez, 1994). O planejamento estratégico diz respeito a horizontes de planejamento longos, incluindo várias rotações, enquanto que o tático diz respeito a períodos mais curtos e à implementação dos planos estratégicos.

O escopo deste trabalho restringe-se ao planejamento otimizado gerencial e considera que existem planos (ou regimes) de manejo opcionais para cada unidade de produção florestal. Estas unidades de produção caracterizam-se pela uniformidade em termos de produtividade e pela homogeneidade da idade e material genético de que são compostas. Um conjunto de unidades de produção constitui o projeto florestal para o qual se pretende definir uma programação de atividades que atenda ao objetivo global do projeto.

Existem centenas de regimes de manejo alternativos para cada uma das unidades de produção. As várias alternativas são obtidas combinando as idades de corte, opções de reforma da floresta, desbastes ou condução de brotação e quaisquer outras características que o gestor queira. É importante salientar que estas alternativas devem ser obtidas, no contexto das organizações, com ajuda de software gerador de alternativas pelo enorme esforço de cálculo.

Os regimes de manejo disponíveis em cada unidade de produção são avaliados de acordo com os seus respectivos valores líquidos presentes. São

considerados todos os custos e receitas do regime para o horizonte de planejamento (Rodriguez e Moreira, 1989; Rodriguez, 1991; Rezende e Oliveira, 1995; Rodriguez et al., 1996b). A escolha do melhor regime em cada unidade de produção baseia-se na maximização do valor líquido presente total e no atendimento das limitações e condições de produção impostas ao projeto.

Se não fossem consideradas as limitações e condições de produção impostas ao projeto, a maximização do valor líquido presente total poderia ser atingida escolhendo-se o regime de mais alto valor em cada unidade de produção florestal. Nesse caso, entretanto, importantes condições, como por exemplo o suprimento de cotas anuais mínimas de produção, não estariam sendo garantidas.

Se um determinado sistema florestal possui muitas unidades de produção e para cada uma escolhe-se apenas o regime ótimo, obtém-se um fluxo irregular de consumo de recursos e de produção. Sabe-se que este fluxo de produção não é, ou tem muito pouca chance de ser, um fluxo regular que atenda às necessidades anuais de matéria-prima típicas das indústrias de base florestal.

A escolha de regimes de manejo para cada unidade de produção deve ser consequentemente realizada de forma conjunta, e não independente. E assim deve ser porque o conjunto das unidades de manejo deve atender aos objetivos de produção de todo o sistema florestal. Se o foco é cada unidade independente, escolhe-se o melhor regime de manejo disponível para a unidade. Mas se o foco é o todo, escolhe-se para cada unidade um regime tal que no conjunto estejam sendo atendidos os objetivos de produção e as limitações operacionais do sistema florestal.

A técnica tradicionalmente usada para solução deste tipo de problemas é a programação matemática (Clutter et al., 1983; Davis & Johnson, 1987; Dykstra, 1984). As razões que levam à escolha dessa técnica podem ser resumidas da seguinte forma: (i) existência de regimes alternativos de manejo para cada unidade de produção; (ii) clara definição de um objetivo a ser

alcançado; (iii) limitação de recursos e imposição de metas periódicas de produção; e (iv) grande número de variáveis para as quais não se consegue escolher intuitivamente a melhor solução.

Problemas de otimização sujeitos a restrições são conhecidos como *problemas de otimização condicionada*, para os quais a programação matemática desenvolveu-se como principal ferramenta de solução (Clutter et al., 1983). Vários autores utilizaram a programação linear para representar o problema básico de tomada de decisão florestal. (Clutter et al., 1983; Dykstra, 1984; Leuschner, 1984; Rodriguez e Lima, 1985; Rodriguez et al., 1986; Buongiorno e Gilles, 1987; Rodriguez e Moreira, 1989; Telhada, 1986; Scolforo, 1990).

Entretanto, a aplicação dessas técnicas, e sobretudo a utilização rotineira das mesmas nas empresas, tem encontrado alguns obstáculos. O capítulo 3 discute a evolução da pesquisa voltada para a solução desses problemas.

2 IMPORTÂNCIA DO PLANEJAMENTO PARA A INDÚSTRIA DE BASE FLORESTAL

Para que se compreenda a importância do planejamento na rotina do gestor florestal é necessária uma visão, ainda que em grandes números, do tamanho e das tendências dos setores que utilizam a madeira como matéria prima fundamental.

2.1 Setores que utilizam a madeira como matéria-prima.

Dentre os setores de expressão nacional que utilizam a madeira como matéria prima existem (i) o siderúrgico, (ii) o de papel e celulose e (iii) o de chapas e moveleiro.

O setor siderúrgico a carvão vegetal apresentou no ano de 1997 um faturamento de US\$ 3,7 bilhões, sendo que cerca de US\$ 1,3 bilhões oriundos de exportações. O setor, que ofereceu em 1997, cerca de 103 mil empregos diretos (ABRACAVE, 1998), consome 85% do carvão vegetal produzido no Brasil.

É importante ressaltar que 75% do carvão vegetal consumido por todos os setores industriais (siderúrgico e outros) é hoje proveniente de florestas plantadas. Deve-se considerar também que o consumo de carvão vegetal dobrou nos últimos dez anos, passando de 8,1 milhões de mdc (metros cúbicos de carvão) para 17,8 milhões, o que mostra a expressividade do crescimento da utilização de florestas plantadas no setor (ABRACAVE, 1998).

Esse crescimento de utilização de florestas plantadas para a produção de carvão não foi acompanhado pelo consumo de toras para produtos de madeira sólida. A ABRACAVE (1998) mostra que em 1997 apenas um terço da madeira consumida por esse setor era proveniente de florestas plantadas: 19,1 milhões de m³ contra 38,6 milhões de m³ provenientes de florestas nativas. Não obstante

essa proporção em relação às florestas nativas ter melhorado nos últimos dez anos, pois era de apenas um quarto de plantadas para três quartos de florestas nativas, ainda houve um grande crescimento de utilização de florestas nativas nesse mercado.

Entretanto, pressões ambientalistas e econômicas, assim como novas tendências mercadológicas e tecnológicas, apontam para uma maior utilização de produtos provenientes de florestas plantadas. Consequentemente, é esperada uma aceleração na utilização de florestas plantadas também nesse setor.

O setor moveleiro faturou em 1997 US\$ 5,6 bilhões, sendo que US\$ 271 milhões correspondem a exportações de móveis de madeira, sendo praticamente inexistente a importação de móveis no Brasil. Os principais pólos moveleiros do país estão no Sul e Sudeste e oferecem cerca de 42 mil empregos diretos (Gorini, 1998).

O setor de celulose e papel é um consumidor economicamente importante de madeira no Brasil e faturou em 1997 R\$ 7,6 bilhões, que corresponderam a 1% do PIB. Contribuiu, ainda, com R\$ 748,9 milhões em impostos e taxas, e pagou R\$ 3 bilhões em salários e encargos para cerca de 67 mil pessoas.

As exportações de celulose e papel no mesmo ano somaram US\$ 2 bilhões. Como o consumo de papel tem crescido muito desde a estabilização da economia e os investimentos no setor não têm acompanhado esse crescimento, o setor importou US\$ 900 milhões em 1997, correspondentes a 977 mil toneladas de papel. Mesmo assim, a produção de papel brasileira é ainda bastante expressiva, suprindo o mercado interno com 3.865 mil toneladas (BRACELPA, 1998).

2.2 Tendência de crescimento da demanda dos produtos que utilizam madeira

Gorini (1998), analisando a indústria moveleira como um todo, afirma existir um potencial de aumento das exportações brasileiras pois os mercados que importam do Brasil possuem taxas anuais de crescimento do consumo positivas. Dentre esses mercados o que apresenta uma das maiores taxas é a América Latina, situação esta que favorece muito o Brasil pela localização geográfica e pelo atraso tecnológico da indústria moveleira nos países latino-americanos.

Gorini (1998) também conclui, após análises do setor, que os investimentos visando ao uso múltiplo de florestas plantadas têm efeitos alavancadores sobre a indústria moveleira e a construção civil. Existiriam também efeitos muito positivos sobre o emprego pois esses são setores importantes na absorção de mão-de-obra, e a entrada de empresas de celulose no mercado de madeira serrada e produtos sólidos de madeira contribuiria para a modernização desse novo segmento da economia nacional.

Dentre os vários produtos florestais (madeira em tora, madeira serrada, painéis de madeira e pastas de madeira) os painéis tem experimentado um crescimento importante nos últimos anos devido ao aumento do consumo de móveis populares nas camadas de baixa renda da população. As unidades da indústria moveleira que investiram em atender esse extrato da população tiveram ganhos significativos no faturamento (Macedo e Roque, 1997; Roque e Valença, 1998).

Segundo Macedo e Roque (1997), existem três tipos básicos de painéis de madeira: os painéis de aglomerado, de MDF (medium density fiberboard) e de compensado. O mercado mundial consumia 132 milhões de m³ em 1995, sendo 2 milhões de m³ no Brasil, e vem crescendo a cada ano. Além do mercado de móveis populares, o consumo para as partes internas de móveis finos e

eletrodomésticos também tem crescido no Brasil.

As importações de painéis de MDF no Brasil têm crescido rapidamente, mostrando que a indústria que o utiliza vem se fortalecendo no país. Cresceu de 534 m³ em 1988 para 65.000 m³ em 1996. Ainda assim, esse mercado não incorporou os consumidores potenciais por ser um produto ainda desconhecido das pequenas e médias empresas brasileiras do setor moveleiro. Segundo Macedo e Roque (1997) o BNDES tem feito investimentos no setor com o objetivo de estruturar indústrias nacionais de MDF para atender à crescente demanda interna e externa.

Estes autores também afirma que, apesar de o painel de aglomerado ser um produto maduro, a indústria brasileira não atende a demanda interna e, para que isto ocorra, a capacidade instalada teria que aumentar em 50% até o ano de 2004, o que significa um aumento de 750 mil m³ sobre a atual oferta.

Já os painéis de compensado atendem a demanda interna e têm 40% de sua produção destinadas à exportação. Isso ocorre, segundo os mesmos autores, devido à inexistência de barreiras para entrada de capital, principalmente de investimento. O setor é também beneficiado pelas previsões de aumento de demanda nacional e internacional.

Macedo e Roque (1997) concluem seu trabalho de análise do mercado de painéis de madeira afirmando que o Brasil conta com todas as características para se inserir no mercado internacional de painéis e ainda atender a demanda interna, pois é detentor de tecnologia de utilização de grandes extensões de florestas plantadas de rápido crescimento.

Em pesquisas ainda mais recentes Roque e Valença (1998) concluem que o mercado mundial de aglomerados vem crescendo a uma taxa de 1,78% ao ano desde 1985. Apesar da produção de 1.200 mil m³/ano atingida em 1997, o crescimento da capacidade instalada ainda não tem sido suficiente para evitar importações como as que ocorreram nesse mesmo ano da Argentina e do Chile.

Além da necessidade de atender à demanda interna de aglomerados, as exportações de aglomerados também podem crescer muito, principalmente para os países da América do Sul. Os mesmos autores afirmam que as perspectivas para o mercado internacional de aglomerado são de expansão à uma taxa aproximada de 3% a.a; já o mercado do MDF crescerá 8% a.a.. No Brasil, as perspectivas são ainda melhores, com crescimento a taxas de 6,5 e 16%, respectivamente. Para atender a esse crescimento da demanda o setor deverá expandir a sua capacidade instalada em cerca de 65% (ano base 1997) até o ano de 2003, o que significaria um acréscimo de 826 mil m³/ano na atual oferta.

O setor de celulose e papel também está em franca expansão, como mostram Macedo e Valença (1996), BRACELPA (1998) e BRACELPA(1999). Macedo e Valença (1996) referem-se ao crescimento do consumo de papel como fruto da estabilização da economia, e a que o aumento das importações estaria sinalizando para a necessidade de mais investimentos no setor. Dados relativos a 1998 da BRACELPA (1999) mostram que não houve inversão da balança comercial no setor apesar do crescimento das importações. Existiria, entretanto, ainda muito espaço para o crescimento do setor no Brasil, especialmente se considerada a condição geográfica, os benefícios em termos de emprego e renda em regiões distantes de centros urbanos e a detenção de tecnologia nas áreas florestal e industrial.

Um exemplo importante de expansão do consumo de papéis são os papéis de imprensa. Macedo e Leite (1998) afirmam que o consumo do papel de imprensa cresceu 60% após o Plano Real, tendo alcançado 680 mil t em 1997. Essa situação provocou aumento nas importações com um desembolso de US\$ 200 milhões em divisas. Em 1997 o Brasil foi o sexto maior importador desse papel, com tendência para uma expansão ainda maior das importações.

Em análise do setor de celulose e papel para o ano de 1998, e em previsões para 1999, a BRACELPA (1999) vê a possibilidade de crescimento

em vários segmentos e otimismo para os próximos dois anos devido a uma tendência de aumento da demanda mundial. O setor planeja aumentar a capacidade instalada de produção de celulose em 1,728 milhões de toneladas e a de papel em 785 mil toneladas no período compreendido entre os anos de 1999 a 2002 (BRACELPA, 1998).

Verifica-se claramente a tendência de crescimento dos setores que se utilizam de madeira. Demonstrou-se também que o Brasil possui condições naturais e tecnológicas para acompanhar os aumentos de demanda esperados.

2.3 Complexidade das decisões do gestor florestal.

São diversos os fatores que afetam o comportamento futuro do mercado e da demanda dos produtos que utilizam madeira como matéria prima, discutidos no item 2.2 (BRACELPA, 1999 ; Gorini, 1998; Macedo e Roque, 1997; Macedo e Valença, 1996; Macedo e Leite, 1998; Roque e Valença, 1998):

- Expansões de grandes indústrias de celulose;
- Rentabilidade abaixo da esperada e conseqüentes retrações nos investimentos;
- Reduções de produção para controlar estoques;
- Mudanças na economia brasileira;
- Mudanças no câmbio e desvalorização do Real;
- Greve em fábrica de papel de imprensa no Canadá;
- Subsídios à exportação no Sudeste Asiático ;
- *Dumping* de competidores;
- Evolução da tecnologia para a produção de cópias – “cultura xerox”
- Aumento de consumo de alimentos das populações de baixa renda que aumenta consumo de papéis usados nas embalagens desses produtos;
- Novas marcas lançadas no Brasil estimulam o consumo de papéis

em campanhas de marketing;

- Queda nas vendas de produtos importados aumenta vendas de papéis para embalagem de produtos brasileiros;
- Aumento no consumo de papéis sanitários devido a aumento de renda da população de baixa renda.

Todos esses fatores influenciam a demanda de produtos com origem florestal e possuem a característica comum de não estarem conectados com a realidade de crescimento biológico das florestas sobre as quais o gestor florestal toma decisões. Em outras palavras, o gestor florestal está pressionado entre duas realidades muito diferentes: de um lado um comportamento das florestas sujeitos a fatores biológicos, climáticos, cujas intervenções têm conseqüências a longo prazo, e de outro lado uma segunda realidade globalizada, rápida e dinâmica, que exige decisões de curto prazo. Uma floresta não se forma em meses. Mesmo no caso das florestas de *rápido* crescimento, são necessários pelo menos 6 anos até a colheita, enquanto que a realidade dos fatores citados envolve cenários que podem se reverter em prazos muito menores.

A percepção dessa diferença de realidades já justificaria por si só a necessidade de ferramentas de gestão suficientemente flexíveis e dinâmicas para introduzir agilidade e precisão na tomada de decisão. Essas ferramentas, entretanto, demandam quantidade significativa de dados que o gestor precisa manipular para tomar decisões.

Apenas para se ter uma idéia do volume de informação manipulada por um gestor florestal pode-se imaginar uma empresa pequena de celulose com capacidade de produção de 200 ton/dia de celulose. A capacidade média brasileira instalada de produção de celulose varia de 100 a 3000 ton/dia (BRACELPA, 1998).

Como exemplo, será considerado que:

- a) a produção anual seja de 66 mil ton de celulose;
- b) a taxa de conversão seja de 167 Kg de celulose por estéreo sem casca (st.sc) de eucalyptus (FLORESTAR ESTATÍSTICO, 1997); e
- c) as florestas apresentem produtividade de 40 st/ha/ano.

Nesse caso, seria necessária uma área total de aproximadamente 10.000 ha e, assumindo-se que uma unidade básica de manejo possui em média 50 ha, conclui-se que o gestor estaria manejando umas 200 unidades de produção. O número de variáveis de decisão sob controle deste gestor chega facilmente a dezenas de milhares se consideradas as centenas de alternativas de manejo disponíveis para cada unidade de gestão.

Para cada uma dessas unidades o gestor precisa decidir-se quanto ao valor das inúmeras variáveis de decisão e simultaneamente considerar dezenas de restrições operacionais e de abastecimento mínimo da indústria a qual a floresta está vinculada.

Esse pequeno exemplo aponta para a necessidade do uso da tecnologia de informação como ferramenta básica de gestão para responder às necessidades de flexibilidade e precisão presentes no contexto dinâmico do setor florestal.

Weintraub (1995) acrescenta à necessidade de tecnologia a necessidade do uso de modelos matemáticos pois:

“muitas combinações são possíveis e experiência e bom senso somente não são suficientes para escolher a melhor combinação entre as milhares e, às vezes, milhões de combinações possíveis”

Segundo este autor, existem alguns pontos que são necessidades básicas do gestor florestal:

- Modelos confiáveis de crescimento das florestas;
- Modelos matemáticos de gestão que representem adequadamente os objetivos, limitações e as interações entre variáveis;
- Controle das operações para garantir a implementação das decisões;

- Recursos humanos bem treinados para utilizar os sistemas de decisão.

Dois fatores importantes têm contribuído para impulsionar o uso de modernas tecnologias de informação: (i) a introdução de computadores pessoais no uso diário das empresas; e (ii) a competitividade dos mercados.

O presente trabalho procura contribuir para a busca de novos modelos de gestão florestal baseados em modelos matemáticos, e oferece ao setor tecnologia eficiente baseada em conhecimento científico de várias áreas: florestal, pesquisa operacional, inteligência artificial e informática.

3 MODELOS DE OTIMIZAÇÃO DO PLANEJAMENTO FLORESTAL

O problema de planejamento florestal possui as características de um problema de programação matemática. Por esta razão os pesquisadores têm buscado soluções utilizando ferramentas da pesquisa operacional. Neste capítulo procura-se resgatar a trajetória dessas pesquisas.

3.1 Uso da Programação Matemática

Rodriguez (1994) analisou as pesquisas na área até então e concluiu que muitas delas se concentraram em apresentar formulações, modelos e soluções baseadas na Programação Linear. Esses trabalhos se preocuparam também em amenizar as limitações das ferramentas matemáticas utilizadas, tais como: linearidade, objetivo único, determinismo e divisibilidade. As aplicações analisadas envolveram quase todos os tipos de formulação de problemas de programação matemática: linear, não-linear, inteira, estocástica, *goal programming* e multiobjetiva.

Além dos autores analisados por Rodriguez (1994), trabalharam também nessa linha Eriksson (1994); Kangas e Pukkala (1992); e Liu e Davis (1995). Borges e Falcão (1999), por exemplo, utilizam a programação dinâmica com o objetivo de determinar a regime de desbastes e regeneração ótimos em povoamentos regulares de *Pinus Pinaster*, alcançando excelentes resultados.

Vários livros texto sobre o assunto referem-se à evolução do uso de modelos de programação matemática na área florestal. Destacam-se os trabalhos de Clutter et al. (1983); Dykstra (1984); Buongiorno e Gilles (1987); e Davis e Jonhson (1987).

Normalmente, as aplicações definem as variáveis de decisão do modelo como representativas da área que as respectivas unidades de produção usam para

conduzir um determinado regime de manejo. É comum, portanto, encontrar, como resultado desses sistemas, soluções que subdividem as unidades de produção entre diferentes regimes de manejo. Essas soluções são em geral indesejáveis do ponto de vista operacional, mas possíveis de ocorrerem do ponto de vista matemático pois trabalha-se com variáveis definidas no espaço real de valores contínuos e positivos (Ignizio e Cavalier, 1994; Davis e Johnson, 1987; Dykstra, 1984; Clutter et al., 1983; e Chiang, 1982).

Para resolver o problema da divisão das unidades de produção entre mais de um regime de manejo, a solução natural seria recorrer à utilização da programação inteira com variáveis binárias 1-0. Estas variáveis permitiriam então definir a associação ou não de um determinado regime de manejo com a respectiva unidade de produção (Rodriguez, 1994).

Os trabalhos publicados envolvendo variáveis inteiras dão ênfase à solução de problemas táticos de curto prazo e de transporte. Rodriguez (1994) cita tais pesquisas e afirma que os algoritmos que solucionam problemas baseados em técnicas de programação inteira são ineficientes para grandes problemas.

Rodriguez (1994) analisou também modelos envolvendo restrições espaciais. Essas restrições agregam grande complexidade aos modelos de planejamento florestais. Em geral, as restrições espaciais envolvem a proibição de colheita de talhões adjacentes durante um certo período de tempo. A procura por modelos que tratem desse tipo de problema continua em evidência na literatura especializada, pois resolve restrições cada vez mais presentes em novas abordagens legais e ambientais de manejo florestal.

Alguns avanços na modelagem das restrições de adjacência podem ser encontrados no trabalho de Murray e Church (1996). Estes autores apresentam a utilização de *cliques* que selecionam e eliminam redundâncias dentre as muitas restrições que seriam necessárias em um modelo de programação inteira para

representar todas as adjacências entre unidades de gestão. Snyder e ReVelle (1996) apresentam uma abordagem diferente de modelagem das restrições de adjacência, e aplicam seu modelo a problemas com 625 variáveis binárias.

Uma outra restrição espacial importante é a restrição de contiguidade. Nesse caso, procura-se garantir que unidades adjacentes recebam um único tratamento, isto é, um único regime de manejo.

A utilização de modelos de Programação Inteira gera problemas combinatoriais muito grandes. Em geral, muito mais difíceis de serem resolvidos do que o equivalente problema de Programação Linear (Glover, 1986; Ignizio e Cavalier, 1994). A dificuldade não está na modelagem do problema, que de fato pouco se altera da Programação Linear, mas sim nos algoritmos disponíveis para a solução de tais modelos.

Os algoritmos para solução de problemas de programação inteira mais utilizados (“branch-and-bound”, “implicit enumeration” e “cutting plane”) são, segundo Ignizio e Cavalier (1994), aplicáveis apenas em problemas de tamanho moderado. Esse certamente não é o caso das aplicações florestais que freqüentemente exigem a definição de milhares de variáveis de decisão. Por esta razão, tornou-se comum a proposição de métodos heurísticos capazes de oferecer boas soluções, com o mínimo de recursos computacionais, para esse tipo de problemas (Murray, 1999; Hoganson e Borges, 1998; Rodriguez, 1994; Yoshimoto e Brodie, 1994a; Weintraub et al., 1995; Ignizio e Cavalier, 1994).

3.2 Propostas heurísticas para a solução de problemas de grande porte

Um método heurístico pode não se basear em um conjunto formal de deduções matemáticas. Normalmente baseados em princípios intuitivos, os métodos heurísticos não garantem necessariamente uma solução ótima matemática. Contudo, heurísticas eficientes e eficazes garantem, freqüentemente, boas soluções, com resultados próximos ao que se estima

seriam encontrados se existissem algoritmos de otimização precisa.

Essas heurísticas apresentam como principal atributo a utilização mínima de tempo e de recursos computacionais (Ignizio e Cavalier, 1994; Yoshimoto e Brodie, 1994a). As heurísticas, portanto, se contrapõem a outros algoritmos como o SIMPLEX, por exemplo, que sempre garantem a solução dos problemas para os quais foram definidos.

A Inteligência Artificial confere às heurísticas um contexto mais amplo e se propõe a resolver os mais diversos problemas, inclusive os problemas combinatoriais de grande porte. Alguns dos princípios da Inteligência Artificial necessários para o propósito deste trabalho são apresentados no Capítulo 4. A literatura florestal especializada menciona o uso de heurísticas diversas vezes. Davis e Johnson (1987), por exemplo, citam uma heurística desenvolvida por Hoganson e Rose (1984) e a apresentam como uma abordagem inovadora para solucionar problemas na área de programação de colheita florestal.

Estudos recentes têm mostrado o potencial das heurísticas para a solução de problemas de programação inteira de larga escala (Ignizio e Cavalier, 1994). Rodriguez (1994), analisando as propostas heurísticas na área florestal, conclui que muitas foram apresentadas para solucionar problemas com restrições de adjacência, pois tais restrições aumentam muito o tamanho do problema e impõem o uso de variáveis inteiras. Algumas das heurísticas apresentadas baseiam-se em métodos de busca aleatória e em métodos de decomposição.

Novas soluções heurísticas continuam sendo propostas na tentativa de resolver problemas mais complexos e com maior eficiência, exatamente como Song (1993) havia previsto. Este autor, em 1993, após fazer uma revisão dos sistemas de suporte à decisão para a solução de problemas de manejo do talhão, considera que existem três estágios de desenvolvimento das pesquisas na área: (i) uso de programação linear usando diferentes funções objetivo e restrições; (ii) a construção de softwares com interface interativa de apoio à decisão baseados

em modelos de programação matemática para a otimização do manejo do talhão; e (iii) a construção de protótipos de sistemas de suporte à decisão para o manejo de florestas contendo modelos de otimização. Conclui seu trabalho de revisão sugerindo que as pesquisas na área de planejamento otimizado deveriam estar voltadas para a construção de sistemas integrados contendo modelos de otimização com simulação do crescimento das florestas utilizando técnicas de inteligência artificial, interface amigável, informações geo-referenciadas e gerenciamento de bancos de dados.

Yoshimoto e Brodie (1994b) apresentam um modelo heurístico que utiliza variáveis inteiras binárias e considera restrições de adjacência incluindo problemas referentes a áreas próximas a cursos d'água. Esses autores aplicam o modelo em um estudo de caso na Siuslaw National Forest, em Oregon, EUA, e afirmam ter chegado a resultados promissores.

Weintraub et al. (1994) propõem a utilização de um algoritmo, que os autores chamam de *column generation*, baseado em programação linear e que trata da questão de adjacência. Utiliza uma heurística para arredondar as soluções não inteiras. Os autores aplicam seu modelo a problemas de porte médio e encontram bons resultados em termos de esforço computacional.

Yoshimoto e Brodie (1994a) apresentam uma nova heurística e a comparam com duas outras heurísticas, para analisar restrições de adjacência e eliminar redundâncias.

Weintraub et al. (1995) propõem um modelo de programação de colheita utilizando variáveis binárias. Usam a formulação de programação inteira incluindo restrições de transporte e concluem que, apesar de terem obtido bons resultados, ainda são necessárias mais pesquisas com o modelo.

Arthaud e Pelkki (1996) utilizam a programação dinâmica associada à heurística A* na otimização do manejo do talhão.

Murray e Church (1995) apresentam três heurísticas para resolver

problemas de planejamento de colheita florestal incluindo restrições de transporte, adjacência e financeiras por período, baseadas nas seguintes técnicas heurísticas: *Interchange*, *Tabu Search*, e *Simulated Annealing*. Os autores apresentam resultados nos quais as heurísticas alcançam valores em torno de 90% da solução ótima.

Murray and Church (1996) apresentam modelos de decisão de colheita florestal utilizando variáveis inteiras e restrições de adjacência e também afirmam que “*técnicas heurísticas têm tido sucesso em gerar soluções para esses problemas*”

Laroze (1999) utiliza uma heurística *Tabu Search* para otimização da colheita e desdobramento das toras em tábuas, incluindo restrições de mercado quanto à qualidade, e afirma ter alcançando valores de 97% da solução ótima matemática para todos os cenários analisados.

Murray (1999) apresenta três importantes recomendações quanto ao uso de variáveis inteiras e inclusão de restrições de adjacência: (i) dado o tamanho dos problemas é indispensável o uso de técnicas heurísticas; (ii) as seguintes técnicas heurísticas podem solucionar esses problemas: *random search*, *interchange*, *simulated annealing* e *tabu search*; e (iii) com base nos dois tipos de problemas estudados, pesquisas futuras podem contribuir para o desenvolvimento de melhores heurísticas.

Rodriguez (1994) apresentou a heurística da Razão-R com bons resultados tanto em termos de comparação com a solução ótima matemática quanto a termos de tempo de processamento. Em um dos testes envolvendo 2584 variáveis inteiras, e utilizando microcomputadores com processadores de geração anterior à linha Pentium, a sua heurística encontrou soluções em aproximadamente 12 minutos. Tais testes mostraram a potencialidade da sua heurística para a solução de grandes problemas de planejamento florestal. Posteriormente Rodriguez e McTague (1997) apresentaram melhorias na

heurística e novos testes.

A próxima seção apresenta o problema matemático para o qual a heurística da Razão-R se oferece como técnica promissora de solução.

3.3 A heurística da Razão-R para problemas de programação inteira

Johnson e Scheurman (1977) classificaram os modelos de programação matemática usados para a solução de problemas de planejamento florestal de longo prazo em Modelo Tipo I e Modelo Tipo II.

No Modelo Tipo I cada variável de decisão representa um conjunto de intervenções programadas para uma unidade florestal de produção, enquanto que no Modelo Tipo II cada variável de decisão corresponde a uma única intervenção em uma unidade florestal (Clutter et al., 1983).

A maioria dos trabalhos aplicando técnicas de programação linear no planejamento florestal se baseiam nesses dois modelos e fazem adaptações e variações de acordo com as particularidades dos problemas tratados. As formulações apresentadas por Murray (1999) considerando restrições de adjacência usam o Modelo Tipo II para formular o problema.

Segundo Rodriguez (1999) a formulação Tipo I permite um acompanhamento eficiente e simples das intervenções em cada unidade. A heurística da Razão-R usa o Modelo Tipo I para formular o problema, e desta forma:

- (1) as variáveis de decisão correspondem à escolha de um único regime de manejo para cada unidade;
- (2) a função objetivo é a soma do resultado obtido em cada uma as unidades;
- (3) as restrições de área garantem a escolha de apenas um manejo para cada unidade; e
- (4) as restrições de produção garantem o fornecimento do produto

florestal nos níveis desejados em cada período do horizonte de planejamento.

A formulação matemática das expressões acima, de acordo com o Modelo Tipo I, pode ser apresentada da seguinte forma:

Maximizar

$$TPV = \sum_{i=1}^I \sum_{j=1}^{J_i} c_{ij} x_{ij}$$

$$\text{Sujeito a } \sum_{j=1}^{J_i} x_{ij} = 1 \quad (i = 1, 2, \dots, I)$$

$$\sum_{i=1}^I \sum_{j=1}^{J_i} v_{ijt} x_{ij} \geq V_t \quad (t = 1, 2, \dots, T)$$

$$x_{ij} = 0, 1$$

Onde:

c_{ij} = valor da unidade florestal i se o regime de manejo j for aplicado

x_{ij} = variável binária (0, 1) representando o regime j aplicado a unidade i

v_{ijt} = quantidade produzida no período t da unidade i se aplicado o regime j

V_t = meta mínima de produção demandada no período t

I = número total de unidades de manejo

J_i = número total de regimes para a unidade i

T = número total de períodos no horizonte de planejamento

TPV = valor total do projeto

A heurística da Razão-R não só se propõe a achar uma solução para o

modelo acima, como também vê nele a inspiração para sua estratégia de busca. O próximo capítulo, em que a heurística é descrita, apresenta detalhes dessa estratégia.

4 DESCRIÇÃO E ANÁLISE DA HEURÍSTICA DA RAZÃO-R

Na primeira seção desse capítulo, a lógica da heurística da Razão-R é descrita e analisada. Nas seções seguintes são apresentados conceitos de inteligência artificial contrapostos aos elementos da Razão-R e à forma como foi construída.

4.1 Descrição da Heurística da Razão R

A versão atual do software que implementa a heurística da Razão-R foi construída para atender aos objetivos deste trabalho. As informações necessárias à heurística são armazenadas em um banco de dados totalmente redesenhado seguindo as regras de modelagem de dados. A sua estrutura segue o modelo relacional e contém as seguintes tabelas: unidades de produção, prescrições de manejo, produção prevista por período para cada prescrição de uma unidade de produção, restrições de produção por período.

De acordo com os princípios de modelagem de dados da ciência da informação, tem-se quatro entidades importantes que guardam os dados necessários à solução do problema em questão. (1) Unidade de produção; (2) Prescrição; (3) Produção, (4) Meta. O diagrama de entidades e relacionamentos está no Anexo B.

Os relacionamentos entre essas entidades são:

- Para cada unidade de produção existem várias alternativas de manejo.
- Para cada uma dessas alternativas de manejo existem várias intervenções que resultam em produção em um determinado período.

Os atributos dessas entidades são:

- Unidade de produção: Encerra o conceito da unidade florestal que produz; e corresponde a uma área geograficamente definida sobre a qual o gestor

florestal opera fazendo um conjunto de intervenções que constituem o manejo. O atributo desta entidade é a área da unidade.

- **Prescrição**: Cada opção de manejo viável para uma unidade de produção é uma prescrição. Cada prescrição é determinada por uma forma de conduzir a floresta naquela unidade, que por sua vez determina uma seqüência de receitas e despesas ao longo do horizonte de planejamento. O valor presente líquido é calculado e armazenado para cada prescrição.
- **Produção**: Representa cada intervenção que resulta em produção em algum período do horizonte de planejamento. O atributo armazenado é a quantidade produzida por unidade de área de um determinado produto no período.
- **Meta**: Níveis de produção que devem ser cumpridos para cada um dos períodos do horizonte de planejamento. O atributo a ser guardado é o valor da meta.

O banco de dados é o ponto de partida da heurística que lê o seu conteúdo e alimenta estruturas de dados que serão a base de representação do problema durante todo o processo de busca heurística. O modelo dessas estruturas foi construído de forma a facilitar a manipulação dos dados durante o processo. Discute-se o modelo dessas estruturas nas seções seguintes como uma das melhorias da versão da heurística atual. Tais estruturas contemplam, no início, o armazenamento de dois grupos muito importantes para a heurística: (i) selecionadas, formado pelo conjunto de prescrições que apresentam o mais alto valor presente líquido por unidade de produção; e (ii) não selecionadas, contendo as demais prescrições.

Ao estado inicial desses dois conjuntos dá-se o nome de solução sem restrições. Essa representaria a melhor solução, se não existissem as restrições operacionais e de atendimento de metas por período.

Os passos seguintes da heurística dependem da definição de mais um

conjunto para viabilizar o processo de busca de soluções melhores. Trata-se do grupo das descartadas, composto pelas prescrições que vão sendo descartadas ao longo do processo.

No estado inicial, o melhor regime para cada unidade está no grupo das prescrições selecionadas. As demais prescrições se encontram no grupo das não-selecionadas e o conjunto descartadas se encontra vazio.

Cada conjunto de prescrições selecionadas define um valor total do projeto que, no contexto da heurística, recebe a denominação de TPV (*total project value*), e é calculado como resultado da soma dos valores líquidos presentes das prescrições selecionadas.

Visto que cada prescrição selecionada resulta em uma seqüência de produção ao longo do horizonte de planejamento, definem-se também as somas das produções por período. A diferença entre a soma das produções por período e a meta de produção para tal período é o déficit por período. Todos os déficits periódicos são somados para a obtenção do total de déficits, que é referenciado por TD (*total deficit*).

Mudanças entre estados ou configurações da base de representação, isto é, do conteúdo de cada conjunto de selecionadas, não-selecionadas e descartadas, resultam da troca de prescrições entre esses conjuntos. Uma prescrição selecionada é trocada por uma não-selecionada e a não-selecionada se torna uma prescrição descartada. Ao trocar prescrições a heurística busca uma situação que atenda as metas de produção.

Entretanto, ao trocar prescrições, a heurística está se distanciando da situação de máximo TPV e, por isso, precisa orientar essa troca de prescrições de forma a se distanciar o mínimo possível desse máximo.

As prescrições a serem trocadas são escolhidas uma por vez. Antes de cada troca, a heurística avalia a modificação medindo o efeito dessa mudança sobre os valores de TPV e TD.

Para cada prescrição candidata a integrar o grupo das selecionadas, define-se a redução que a sua seleção causa no TD e no TPV. A razão entre a redução do TD e a redução do TPV é definida como a Razão-R, e quantifica o ganho devido à redução do déficit de produção por unidade de redução no valor total do projeto. Durante o processo heurístico essa razão é calculada para avaliar as prescrições não-selecionadas e descartadas. A troca é guiada pela seleção da prescrição de maior Razão-R. Essa prescrição substitui, no grupo das selecionadas, aquela associada com a mesma unidade de manejo da que entra no grupo, e a substituída passa para o grupo das descartadas.

Define-se, após cada troca de prescrições, um novo estado. O processo se repete até que TD seja igual à zero (condição de terminação) e como a heurística da Razão-R tende a reduzir o déficit sem se afastar muito do valor máximo de TPV, acredita-se que o estado alcançado esteja próximo da solução ótima.

A primeira implementação da heurística apresentada por Rodriguez (1994) considerava como potenciais candidatas para a troca apenas as prescrições não selecionadas. Rodriguez e McTague (1997) apresentaram nova versão propondo a visita periódica ao grupo das descartadas. A versão que está sendo apresentada neste trabalho apresenta uma forma sistemática de testar estratégias de busca no grupo das descartadas tentando encontrar soluções melhores.

Essas estratégias são representadas por dois parâmetros:

- α : representa a iteração a partir da qual a heurística busca prescrições no conjunto das descartadas e;
- β : representa o intervalo entre iterações para que a heurística busque prescrições no conjunto das descartadas .

É importante destacar que, nas iterações de busca entre as descartadas, o guia não precisa mais ser a Razão-R. Basta avaliar apenas a redução do déficit,

pois espera-se que as prescrições descartadas tenham sempre pouco efeito sobre a redução do TPV.

Quando se atinge déficit zero, a heurística entra em uma fase chamada “green phase”, na qual o sistema de controle tenta melhorar a TPV mantendo o déficit zero. Nessa fase, a heurística se guia apenas pelo potencial de ganho no valor do TPV. A troca que proporciona o maior TPV é efetuada. Nessa fase a heurística avalia prescrições contidas nos conjuntos das não-selecionadas e descartadas. A condição de terminação é a não existência de uma possível troca que aumente o TPV.

Para facilitar a análise de todo o processo heurístico, foi criado um banco de dados relacional para guardar os resultados e os passos da heurística. Ao final do processo guardam-se os valores finais de TPV, TD, os parâmetros que definem a estratégia de busca entre as descartadas, tempos de execução, número de iterações, o conjunto das prescrições selecionadas, a seqüência de trocas, e os valores alcançados de produção por período. O modelo para armazenamento destes dados é mostrado no Anexo B.

O Anexo C descreve com detalhes os passos da heurística usando a linguagem algorítmica. As próximas seções discutem a Razão-R à luz dos conceitos teóricos de inteligência artificial. Ao longo da discussão procura-se mostrar:

- como tais conceitos guiaram as melhorias na heurística;
- que a heurística da Razão-R está de acordo com tais princípios.

4.2 Inteligência Artificial e Busca Heurística

Segundo Nilsson (1982) os métodos e técnicas de inteligência artificial têm sido aplicados em diversos tipos de problemas, dentre eles o *scheduling*, problemas que envolvem a programação de atividades no tempo. O autor afirma que a inteligência artificial possui técnicas capazes de solucionar esses

problemas, apesar de serem complexos e de difícil solução se para grandes problemas.

4.2.1 Sistemas de inteligência artificial

Nilsson (1982) menciona um conceito que ajuda a ter uma visão de como deve ser construída uma solução baseada em princípios de inteligência artificial. Um sistema de inteligência artificial é um sistema no qual um banco de dados global é manipulado por certas operações bem definidas sujeitas a uma estratégia de controle. Um sistema de inteligência artificial possuiria, então, três componentes independentes: (i) banco de dados global, (ii) regras de produção, e (iii) sistema de controle.

O banco de dados é a estrutura de dados utilizada, que pode variar de uma simples matriz até a um complexo banco relacional. As regras de produção operam sobre o banco de dados. Cada regra tem uma pré-condição para que seja aplicada, e a aplicação de uma regra altera o banco de dados. Já o sistema de controle escolhe, dentre as regras aplicáveis, a que deve ser aplicada e testa a condição de terminação.

O banco de dados pode ser acessado por todas as regras. Uma regra não chama outra regra como nos sistemas convencionais. A comunicação entre regras é feita somente via banco de dados. O autor enfatiza a necessidade de tais componentes serem independentes.

Na Razão-R, existem três conjuntos de dados: as prescrições selecionadas, as não selecionadas, e as descartadas, isto é, as que já foram selecionadas em algum momento e, em seguida, descartadas. No início da heurística, o sistema de controle lê do banco de dados relacional os dados referentes às unidades de manejo, às prescrições e à seqüência de produção de cada uma das prescrições de manejo. Alimenta, a seguir, um conjunto de estruturas com dimensões variáveis para as quais a memória é alocada

dinamicamente. Durante o processamento heurístico, o sistema de controle opera apenas com essas estruturas. O fato de trabalhar com estruturas de alocação dinâmica aumentou substancialmente a performance do sistema de controle.

A nova forma de representação do problema foi uma das melhorias feitas na corrente versão da heurística, cujos resultados são apresentados no capítulo 5.

A regra de produção é trocar a prescrição de uma determinada unidade que apresente a maior Razão-R dentre todas no conjunto.

O sistema de controle é o programa que calcula as razões-R para todas as prescrições, escolhe a maior, faz a troca e testa a condição de terminação. A condição de terminação é atender às metas de produção do problema.

Segundo Nilsson (1982), desenvolver uma boa forma de representar os dados em um problema é uma arte necessária na solução de problemas práticos com técnicas de inteligência artificial. Seguindo essa recomendação, introduziu-se no sistema de controle uma melhoria na regra de produção: ao invés de manterem-se os conjuntos de prescrições descartadas, selecionadas e não-selecionadas em locais separados e trocar prescrições de lugar, controla-se apenas o status da prescrição sem movê-la de lugar no espaço alocado na memória.

Em versões anteriores, o sistema de controle operava diretamente com tabelas em disco. Nas versões anteriores, o sistema entendia que existiam três conjuntos de dados. Para fazer uma troca o sistema realizava as seguintes operações:

- (i) apagava uma prescrição do conjunto de não-selecionadas;
- (ii) acrescentava essa prescrição no conjunto das selecionadas;
- (iii) retirava do grupo das selecionadas a prescrição associada com a unidade de manejo para a qual se escolheu uma nova prescrição; e
- (iv) incluía essa prescrição no grupo das descartadas.

Na versão atual, o sistema representa o problema como uma estrutura

tridimensional, em que a primeira dimensão associa-se com as unidades de produção, a segunda dimensão com as prescrições, e a terceira dimensão com os períodos. A primeira e segunda dimensões definem prescrições de uma unidade que podem estar selecionadas, não selecionadas ou descartadas. Assim, para fazer uma troca, o sistema tem que fazer apenas uma operação de atribuição, trocando o status da prescrição.

Além dessa estrutura principal, o sistema trabalha com outras estruturas que facilitam o acesso à principal. Existem uma estrutura que guarda a posição atual da prescrição selecionada por unidade de produção e outra que guarda as metas de produção.

O sistema de controle da Razão-R possui a propriedade da clareza de definição desejável em elementos de um sistema de inteligência artificial, sendo os seus elementos facilmente distinguíveis e de fácil compreensão. Isto torna a heurística fácil de ser adaptada às diferentes tecnologias de software e hardware.

4.2.2 Estados e Movimentos

Rich e Knight (1993) e Nilsson (1982) referem-se aos conceitos de estado, movimento e meta em sistemas de inteligência artificial. Estado é a configuração do banco de dados em um determinado momento. O estado do banco de dados é alterado quando se aplica uma regra, ocorrendo, um movimento. Meta é o estado que se quer atingir. O conjunto de todos os estados possíveis é o espaço do problema. Nessa linguagem de estados e movimentos, a solução do problema é a seqüência de movimentos que leva o sistema de controle do estado inicial ao estado meta.

Na atual implementação da heurística da Razão-R, um estado é definido pela forma como a estrutura principal associa as prescrições com os grupos de selecionadas, não-selecionadas e descartadas. Um movimento é efetuado toda vez que uma dessas associações é modificada pelo sistema de controle. Cada

troca de prescrições entre grupos define um novo estado. A meta é um estado que atende as restrições de produção de todos os períodos.

O estado inicial é obtido pela seleção da melhor prescrição para cada unidade sem se considerarem as restrições de produção. O espaço do problema é o conjunto de todas as combinações possíveis de escolha de uma prescrição para cada unidade de manejo. Esse espaço não precisa ser totalmente percorrido pela Razão-R. O sistema de controle conduz os movimentos do estado inicial ao estado-meta. A Razão-R guia os movimentos para se chegar à meta com o menor número possível de estados intermediários.

Na maioria dos problemas de inteligência artificial, as informações disponíveis sobre o problema não são suficientes para garantir a escolha da regra mais apropriada a ser aplicada. Por essa razão, os sistemas de controle são caracterizados por processos de busca para os quais regras são tentadas até se atingir a condição de terminação. Sistemas de controle eficientes requerem conhecimento suficiente sobre o problema para que a regra selecionada tenha uma boa chance de ser a melhor.

Na Razão-R, o conhecimento do problema, a que se referem os autores de inteligência artificial, está baseado no modelo Tipo I de programação linear para problemas de planejamento florestal. O conhecimento do problema aponta para a existência intuitiva da Razão-R, ou seja, redução do déficit de produção por unidade de redução no valor total do projeto. A qualidade do guia garante um número eficiente de movimentos. A unidade de produção que vai ter sua prescrição trocada é a que mais contribui, no momento, para se chegar ao estado-meta.

Nilsson (1982) distingue dois tipos de estratégias para os sistemas de controle: irrevogável e tentativa. Na estratégia irrevogável, uma regra selecionada e aplicada não volta a ser considerada mais tarde. Na estratégia tentativa, essa regra volta a ser considerada, e o banco de dados retorna a um

estado anterior para que se tente uma nova estratégia.

O sistema de controle da Razão-R não é exatamente um sistema irrevogável, mas também não é um sistema de tentativa. As prescrições que foram trocadas por prescrições melhores são colocados no conjunto dos descartados. Essas prescrições são reconsideradas periodicamente. Quando alguma das prescrições previamente descartadas é novamente selecionada, o estado resultante não necessariamente reflete as condições de quando esse regime pertencia ao grupo das selecionadas.

No tipo de estratégia de tentativa, Nilsson (1982) descreve controles do tipo busca em árvore. Cada estado do sistema de controle determina todas as regras aplicáveis. Cada estado é um nó e as opções são os galhos. O sistema de controle escolhe o melhor, faz um movimento em direção ao nó escolhido e repete esse procedimento sucessivamente.

O autor também discute algumas propriedades dos sistemas comutativos e de decomposição. Um sistema comutativo se caracteriza pela existência de regras que participam da solução e, se aplicadas em qualquer ordem, resultam sempre na mesma solução. Um sistema é de decomposição quando o banco de dados é dividido e as regras são aplicadas em partes do banco, produzindo o mesmo resultado do obtido se as mesmas regras forem aplicadas ao todo.

A Razão-R é comutativa pois se for trocada a ordem de substituição das prescrições, desde que feitas as mesmas substituições, o estado-meta será sempre o mesmo. Mas a Razão-R não é de decomposição, pois o cálculo do guia que orienta os movimentos não permite a subdivisão do problema. Quanto ao controle do tipo busca-em-árvore, a heurística também gera "galhos" na forma de prescrições que são avaliadas pela Razão-R para atualização do banco de dados.

4.2.3 Informações heurísticas

Uma característica importante da seleção de regras é a quantidade de informação ou conhecimento que se tem do problema. Um extremo é a seleção de regras completamente aleatória e o outro extremo é um sistema de controle que possui conhecimento suficiente para selecionar a regra correta todas as vezes. A eficiência de um sistema de inteligência artificial depende de como a estratégia de controle se posiciona entre os dois extremos.

Se o custo de uma heurística for definido com base no "esforço" de aplicação das regras ou de controle, tem-se que o controle aleatório possui um custo de controle baixo e de aplicação das regras alto. O controle ideal, entretanto, deve possuir custos de controle de aplicação melhor balanceados. Parte da arte de desenhar um sistema de inteligência artificial é decidir como balancear esses dois custos. O custo mínimo está entre os dois extremos. O que, na prática, se traduz em um sistema de controle que use eficiente e eficazmente o conhecimento disponível sobre o problema sem custos altos (Nilsson, 1982).

As informações sobre o problema que orientam o sistema de controle na seleção de regras são denominadas informações heurísticas. Um sistema de controle que não usa informações heurísticas é classificado como um sistema desinformado. Os demais são denominados buscas heurísticas.

Informações heurísticas podem ser usadas para ordenar as regras candidatas a serem aplicadas sobre o banco de dados, ou sobre a escolha do nó na árvore de decisão. Essas informações produzem métodos que são usados nos cálculos como *funções de avaliação*. Estas funções são baseadas em várias idéias: a probabilidade do nó estar no melhor caminho, a distância ou diferença entre o nó e o estado-meta, o sistema de pontuação etc.

Rich e Knight (1993) apresentam o conceito de função heurística cujo propósito é guiar o processo de busca no caminho mais promissor, sugerindo o caminho a ser seguido primeiro quando houver mais de uma opção de caminho a

ser seguido. Quanto mais precisamente a função heurística estima os méritos reais de cada nó da árvore de busca, mais direto é o processo de solução.

A escolha da função de avaliação é crítica para uma busca heurística. Será considerada uma boa função se os custos do sistema forem baixos, e se resultar em uma boa representação da realidade.

Conclui-se que o bom senso e a experimentação devem guiar o programador heurístico na construção das funções heurísticas, pois o custo mínimo de uma heurística está entre os dois extremos: um caminho muito longo de busca ou uma solução direta.

É precisamente neste ponto que a Razão-R tem a sua maior vantagem. A função de avaliação da Razão-R é baseada na distância entre o estado atual e o estado meta, e é uma razão entre dois números muito fáceis de serem calculados. E, apesar da sua simplicidade, representa o problema com muita propriedade.

É necessário, entretanto, o estudo da precisão de cada movimento, e por esta razão uma das melhorias importantes realizadas na função heurística foram as regras de desempate no momento da escolha da melhor Razão-R. Depois de calculadas as Razões-R para todos as prescrições descartadas e/ou não-selecionadas ocorriam empates na escolha da prescrição. Essas regras são baseadas na redução do valor do projeto (TPV) ou na redução do déficit (TD).

Além das regras de desempate na função heurística, o sistema de controle foi simplificado e otimizado visando obter maior clareza e menores custos computacionais.

4.2.4 Estratégias de controle e técnicas de busca heurística

Como vimos nas seções anteriores, o sistema de controle escolhe dentre as regras a que deve ser aplicada para possibilitar um movimento. É preciso conhecer melhor as estratégias de busca. Rich e Knight (1993) apresentam duas estratégias básicas: busca em profundidade e busca em amplitude. A busca em

amplitude considera todas as possibilidades, isto é, tem uma visão de todos os estados, de todo o espaço do problema. A busca em profundidade explora apenas os nós do caminho percorrido. A busca em amplitude gera toda a árvore e por isso, se houver uma solução, ela certamente será encontrada.

Dentre as várias técnicas de busca descritas por Rich e Knight (1993), duas são particularmente interessantes para o escopo deste trabalho: (i) subida de encosta pela trilha mais íngreme e (ii) busca pela melhor escolha. Na técnica da subida de encosta pela trilha mais íngreme, avaliam-se para cada estado todos os movimentos possíveis de serem feitos a partir desse estado e escolhe-se o melhor deles como próximo estado. Gasta-se recurso computacional para a avaliação de todos os movimentos possíveis, mas a função heurística indica o melhor movimento, ou o que mais tem chance de levar ao estado-meta mais rápido. Mas esta técnica pode não levar à solução, isto é, pode-se chegar a um estado terminal determinado por um máximo local, ou a estados em que todos os movimentos levam sistematicamente a resultados semelhantes, chamados platôs.

A busca pela melhor escolha é semelhante à busca pela trilha mais íngreme, mas as opções descartadas não são de todo ignoradas. São novamente avaliadas quando necessário, isto é, se o caminho escolhido não parecer promissor.

Considerando a estratégia de busca em profundidade, a Razão-R não utiliza exatamente a técnica da subida pela trilha mais íngreme, porque pode eventualmente retornar ao conjunto das descartadas. Por considerar as prescrições descartadas, pode-se considerar que a Razão-R se aproxima da heurística baseada em estratégia de melhor escolha.

4.3 Técnicas heurísticas para modelos de programação inteira

Ignizio e Cavalier (1994) citam a programação heurística como um dos métodos mais promissores para a solução de problemas de programação inteira:

“*abre-se a porta para um novo mundo de solução de problemas - passamos do uso de algoritmos para o desenvolvimento de métodos heurísticos*”. Enquanto um algoritmo garante a solução ótima para problemas com variáveis inteiras, os métodos heurísticos chegam a soluções aceitáveis. Ao contrário dos algoritmos, entretanto, os métodos heurísticos podem ser aplicados à solução de grandes problemas e levar a soluções com baixo custo computacional.

Para esses autores, a programação heurística envolve a busca de uma solução para um determinado problema com base em um conjunto específico de operações básicas, em que a solução é produzida depois de um número finito de passos. Afirmam que existem oito tipos de heurísticas aplicáveis a problemas práticos, dos quais a busca por permutação se aplica normalmente a problemas de *scheduling*. Este tipo de heurística é eficiente para problemas muito grandes e é fácil de ser implementado.

A busca por permutação pode ser resumida em três passos:

- i) *Inicialização*: obtenção de uma permutação inicial.
- ii) *Busca na vizinhança*: investigação de permutações até que se encontre aquela que melhora a solução, fixando-a como nova solução.
- iii) *Teste da condição de terminação*: interrupção do processo se nenhuma melhoria puder ser conseguida.

A heurística da Razão-R se assemelha à busca por permutação, exceto pelo fato de que não faz a permuta assim que encontra um estado que melhora a solução. De fato, todas as permutas possíveis são verificadas antes da troca.

4.4 Abordagem moderna de inteligência artificial: agentes inteligentes

Russel e Norvig (1995) conceituam um agente inteligente como algo que percebe seu meio através de sensores e age sobre ele utilizando suas ferramentas chamadas *effectors*. Tanto um software como um robô podem ser vistos como

agentes inteligentes. Os autores chamam os agentes tipo software de *softbots*, lembrando os *robots*.

Os agentes inteligentes agem de forma racional, por isso, buscam, para cada seqüência de fatos percebidos, maximizar sua medida de performance. Essas medidas de performance são os graus de sucesso do agente. Por esse motivo, ao construir um agente inteligente, que no escopo deste trabalho é um *softbot*, deve-se buscar identificar cada um dos seus elementos. No caso estudado, o *softbot* é o guia baseado no cálculo da Razão-R. O ambiente para ele são as muitas possibilidades de combinações de prescrições selecionadas e não-selecionadas. Seus sensores percebem o ambiente calculando e avaliam as possibilidades ao seu redor. O agente decide racionalmente e maximiza a sua performance escolhendo a maior Razão-R e age sobre o meio trocando prescrições. Na verdade, o ambiente com o qual a Razão-R interage é uma representação do mundo real, ou uma aproximação dele através do modelo de dados.

Segundo Russel e Norvig (1995), a inteligência artificial se ocupa de projetar e construir esses agentes. Para existirem, os agentes precisam de um aparato tecnológico, incluindo computadores, equipamentos periféricos e softwares de vários tipos, o que significa que, para projetar e construir agentes, trabalha-se com computadores e software.

4.4.1 O agente que busca atingir metas

Russel e Norvig (1995) evoluem na definição de agentes inteligentes e apresentam um agente baseado em metas (*goal-based agents*) em que a performance de um agente depende das metas que quer alcançar. Esse agente se contrapõe ao agente que age por reflexo (*reflex-agent*) - que apenas reage ao meio e que segue regras para tal. O *goal-based agent* trabalharia mais eficientemente e a palavra busca teria um significado especial. Assim, agentes

baseados em metas seriam agentes que resolvem problemas (*problem-solving agent*) e que procuram uma seqüência de ações que os levem a estados desejados. A meta, para Russel e Norvig (1995), é um conjunto de estados do ambiente que apresentam características específicas.

É evidente que o guia da heurística da Razão-R é um *problem-solving agent* pelas suas características. Ele procura determinar uma seqüência de ações, que são as trocas de prescrições, com o objetivo de encontrar um estado que satisfaça a condição de déficit zero de produção em relação a produção desejada. E a meta é o conjunto de combinações de prescrições que tornam o déficit igual a zero.

A solução para o problema pode estar no estado atingido pelo agente ou na seqüência de ações do agente. Para o agente da Razão-R, encontrar um estado meta não é suficiente, ele precisa também fazer o menor caminho entre o estado inicial e o estado meta, pois o caminho mais curto também significa perder menos no valor total do projeto. É importante ressaltar que, ao atingir a meta na *green phase*, o agente mantém-se fiel à meta de déficit zero.

Russel e Norvig (1995) definem as quatro partes do problema a ser solucionado pelo agente:

- i) o estado inicial;
- ii) as operações ou função de sucessão;
- iii) a função de teste de terminação;
- iv) a função de custo do caminho.

A função de sucessão é uma função que, dado um estado atual, retorna um conjunto de estados possíveis para os quais o agente pode se movimentar. No problema da Razão-R, a função de sucessão é a decisão que o sistema de controle faz, a partir dos parâmetros de avaliar ou não o conjunto das prescrições descartadas. Essa função define o conjunto de prescrições possíveis de troca no momento, que não depende do estado atual, mas sim dos parâmetros α e β

definidos antes de o agente iniciar sua trajetória.

A função de teste de terminação na Razão-R é o teste do déficit igual a zero. Mas a função de terminação muda quando o agente atinge a *green phase*. A condição de terminação dessa fase é atingida quando o agente da Razão-R não consegue mais melhorar o TPV com trocas de prescrições.

A função do custo do caminho é a própria Razão-R, calculada para todos os caminhos alternativos.

Russel e Norvig (1995) também definem estratégias de buscas e as características mais importantes que deveriam ser usadas para avaliar uma estratégia:

- i) busca completa;
- ii) complexidade de tempo;
- iii) complexidade de espaço;
- iv) otimalidade.

Uma estratégia é completa se varre todo o espaço do problema, e, conseqüentemente, se existir uma solução, o agente a encontrará. Essa qualidade é equivalente à busca em amplitude definida por Nilsson (1982). Deve-se analisar quanto tempo o agente demorará para encontrar a solução, quanto de recurso computacional o agente irá consumir na busca e, por fim, se o agente encontrará a solução de melhor qualidade.

Para o agente da Razão-R tem-se que:

- i) O agente não faz uma busca completa. Ele toma apenas uma direção e não retorna para testar outros caminhos. É uma busca em profundidade, avalia apenas as opções de caminho ao longo da busca;
- ii) O agente tende a não gastar muito tempo na busca, pois a complexidade das operações não é grande e os caminhos são relativamente curtos para o tamanho do problema;
- iii) O agente também tende a não consumir muitos recursos visto que

não guarda as características dos estados pelos quais já passou. A condição de complexidade de espaço máxima para o agente se define pela quantidade total de estados possíveis. Na Razão-R, o agente tende a encontrar a solução com a exploração mínima do espaço;

iv) Não há garantia de que o agente encontrará a solução ótima para o problema, e sim de que procurará se manter próximo à ela.

Essas características inspiraram uma análise mais profunda do agente Razão-R e influenciaram as alterações realizadas. O fato de a busca não ser completa (primeira característica), isto é, de o agente seguir um caminho e não retornar para analisar caminhos mais promissores faz com que o estado terminal seja normalmente um máximo local. Como esses ótimos locais resultam em valores potencialmente próximos do ótimo global, é coerente imaginar que variações na estratégia de busca resultariam em diversas soluções boas.

Na primeira versão da Razão-R, apresentada por Rodriguez (1994), calculava-se a Razão-R de formas diferentes na tentativa de seguir caminhos alternativos de busca. Mais tarde, Rodriguez e McTague (1997) apresentaram a estratégia de retorno aos descartados também com o mesmo objetivo. Apresenta-se agora uma sistematização dessas estratégias, propondo que o sistema de controle faça a busca heurística várias vezes, uma para cada par diferente de parâmetros $[\alpha, \beta]$.

Essa melhoria era imprescindível, pois, de acordo com Glover (1986), a maior limitação dos métodos heurísticos envolvendo alternativas discretas é a “habilidade das heurísticas de caírem nas armadilhas dos máximos locais”. Por isso é necessário organizar a exploração dos caminhos possíveis usando boas estratégias para fugir desses máximos locais.

Quanto à segunda característica, tempo, alterou-se a representação do problema visando à redução do número de operações e conseqüentemente o tempo computacional. Outra melhoria importante nesse sentido foi a revisão de

todo o algoritmo, procurando-se eliminar ineficiências que gastem recursos em operações desnecessárias. Cabe aqui ressaltar que a simplicidade de cálculo da Razão-R, uma razão entre dois números obtidos através de somas, é a sua grande força em termos de pequeno tempo computacional. A terceira característica, espaço, não é uma limitação para o problema em questão, pois o pior cenário de avaliação da heurística é função direta do número total de alternativas nos conjuntos de prescrições não-selecionadas e descartadas. Mesmo para problemas grandes, o custo de aumento de memória e discos dos computadores modernos é irrisório, se comparado ao montante de recursos envolvidos no problema real, e a velocidade de melhoria dos recursos de hardware é maior que a velocidade de evolução dos recursos de software.

Quanto à quarta característica, otimalidade, deve-se considerar que as buscas heurísticas têm como objetivo apenas chegar perto da solução ótima a baixo custo (Ignízio e Cavalier, 1994 ; Russel e Norvig, 1995; e Morton e Pentico, 1996). Testes com a heurística da Razão-R têm demonstrado a possibilidade desta incluir, no seu conjunto de soluções, a própria solução ótima dos problemas.

4.4.3 Buscas heurísticas

Na abordagem do agente inteligente, Russel e Norvig (1995) classificam as buscas em duas grandes categorias: as buscas desinformadas, ou buscas cegas, e as buscas informadas, ou heurísticas. As buscas heurísticas são as que se baseiam em informações do problema na formulação dos elementos do problema: função de custo, de terminação, de sucessão e estado inicial.

Embora as buscas cegas sejam menos eficientes que as buscas heurísticas, para muitos problemas reais são necessárias. As estratégias de buscas cegas são, ainda, importantes para compreensão das estratégias de buscas heurísticas.

Nas buscas heurísticas, o conhecimento do problema é aplicado na decisão de qual será o próximo nó a ser expandido no conjunto de nós possíveis. A Figura 2 mostra um esquema de busca e a escolha do nó a ser expandido a cada passo.

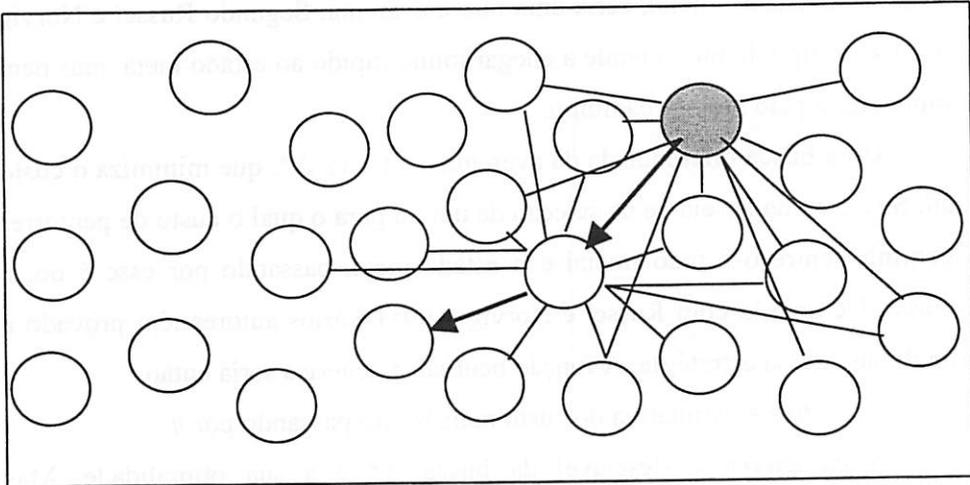


FIGURA 2 – Esquema de busca heurística

A estratégia de expansão para o nó mais promissor é chamada de *best-first-search*. Uma das formas mais simples de *best-first-search* é de minimizar a estimativa de custo para chegar na meta. Nessas buscas a função de custo é chamada de função heurística. A função heurística genérica é representada por:

$h(n)$ = estimativa de custo do caminho mais barato entre o nó n e o estado meta.

Uma busca que usa esse tipo de função é chamada de busca avarenta (*greedy search*). Recebe este nome devido à sua visão imediatista do problema, que procura dar o melhor passo a cada nó, levando o agente mais rapidamente na direção da meta. Essa busca não se preocupa em analisar se, a longo prazo, esse é o melhor caminho, isto é, se dar um passo num momento específico não

implica em seguir um caminho mais longo em direção a meta devido aos passos posteriores. Esta é a causa da não otimalidade da busca avarenta. Se a função heurística da Razão-R considerasse apenas a redução no total de déficit e do estado meta, se só se interessasse por movimentos com TD igual a zero e não próximos ao estado inicial, seria uma busca avarenta. Segundo Russel e Norvig (1995), esse tipo de busca tende a chegar muito rápido ao estado meta, mas nem sempre passa pelo melhor caminho.

Uma busca diferenciada da avarenta é a busca A*, que minimiza o custo total. Sua escolha baseia-se na seleção de um nó para o qual o custo de percorrer o caminho entre o estado inicial e o estado meta, passando por esse é nó, é mínimo. De acordo com Russel e Norvig (1995), vários autores têm provado a otimalidade dessa estratégia. A função heurística genérica seria então:

$$f(n) = \text{estimativa do custo mais barato passando por } n$$

A característica desejável da busca A* é a sua otimalidade. Mas determinar uma função que estime o custo total passando por um determinado nó não é viável para o problema florestal, pois uma das características do estado meta não é conhecida até que se chegue lá: sua TPV.

Se considerarmos que a Razão-R mede quão promissor é o próximo nó nas duas características do estado meta (TD=0 e menor redução do TPV), pode-se dizer que a Razão-R é uma busca avarenta. E que traz consigo a característica muito desejável que é a de chegar rapidamente ao estado meta. Mas ela não é uma busca precisamente avarenta pois encerra o conceito da visão de todo o caminho.

Desta forma possui a característica importante da A*, que é uma função heurística que enxerga a direção a ser seguida, apesar de não calcular o custo de todo o caminho. A Razão-R considera o valor do estado inicial (TPV) e do estado meta (TD). É como se existisse uma amarra entre os dois estados que não deixa que a busca se desvie muito da direção Início-Fim como está

esquemático na Figura 3.

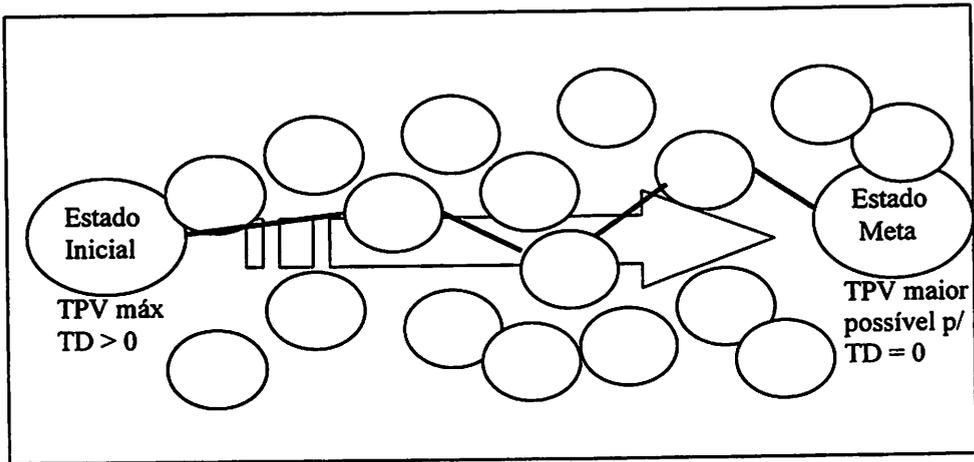


FIGURA 3 - Direção Início-Fim

A Razão-R possui duas características desejáveis, portanto:

- i) Chega à solução em um pequeno número de iterações;
- ii) Chega a soluções muito próximas do ótimo.

Uma constatação importante demonstrada nos testes apresentados por Rodriguez e McTague (1997) e Rodriguez (1999) é que nas diversas estratégias de busca aos descartados, uma variação da função de sucessão, o caminho seguido pelo agente é obrigatoriamente diferente, mas isso não o desvia da direção. A explicação plausível para esse fato é que a função heurística da Razão-R é muito forte ao apontar a direção que deve ser seguida. Essa força em apontar a direção substitui a necessidade de conhecimento de características precisas do estado meta pelo fato de o agente de busca frequentemente chegar muito próximo da solução ótima.

Russel e Norvig (1995) apresentam também uma categoria de problemas cuja estratégia de busca não é afetada pelo caminho para se chegar à solução.

Para esses casos os pesquisadores têm utilizado os algoritmos iterativos de melhoria. Esta definição de Russel e Norvig (1995) se assemelha à definição de Ignizio e Cavalier (1996) de buscas de permutação para solução de problemas de *scheduling*.

A idéia básica desses algoritmos é, a partir de uma configuração inicial, fazer uma alteração de cada vez até atingir uma solução. A Razão-R troca prescrições de forma muito parecida com a forma que esses algoritmos trabalham, mas se diferencia em dois aspectos importantes:

- i) As características da configuração de um estado são parte importante da solução, mas a solução completa precisa da garantia de que o agente tenha trilhado o menor caminho desde o estado inicial.
- ii) A Razão-R é bastante específica na melhoria da configuração e guia os movimentos através de uma estratégia orientada de busca.

A Razão-R mantém na memória somente a configuração do estado atual, pois não precisa dos dados dos outros estados, apenas da garantia de ter trilhado o melhor caminho. A melhoria realizada nessa versão, guardar no banco de dados as características principais de cada passo, contribui para a análise do caminho seguido pelo agente.

Russel e Norvig (1995) descrevem dois tipos de estratégias nessa categoria: (i) Escalada pela trilha mais íngreme, citada também por Rich e Knight (1993), já discutida seção 4.2.4; e (ii) *simulated annealing*.

Enquanto a estratégia da escalada só faz movimentos que melhoram a situação atual, o *simulated annealing* permite movimentos no sentido de piorar a situação, desde que temporariamente.

Uma variação interessante da escalada pela trilha mais íngreme é o reinício randômico. Quando o agente de busca encontra um máximo local, ele começa de um novo ponto de partida escolhido aleatoriamente, faz nova busca e pára quando encontra outro máximo local. Repete esse processo um número

definido de vezes ou até não encontrar mais soluções melhores em várias iterações.

O sistema *batch*, criado para a Razão-R, lembra esse processo. Não gera pontos de partida aleatórios, começa sempre do mesmo estado inicial, mas segue caminhos um pouco diferentes na tentativa de encontrar máximos locais diferentes. Esse passo contribui para a criação de estratégias alternativas de movimentos entre estados, potencializando a possibilidade de melhoria das soluções encontradas.

O *simulated annealing* é discutido na próxima seção juntamente com outras heurísticas como o *Tabu Search* e os *algoritmos genéticos*, categorizadas como heurísticas baseadas em iterações de melhoria.

4.5 Algoritmos Iterativos de Melhoria

Russel e Norvig (1995) conceituam os algoritmos iterativos de melhoria como agentes inteligentes que melhoram a solução a cada passo, ou a cada iteração. Mas Morton e Pentico (1996) chamam esse tipo de busca de *extended neighborhood search* pela sua natureza de melhoria a cada iteração. Segundo estes autores essas heurísticas se caracterizam pela facilidade de implementação e por alcançarem boas soluções, sobretudo quando utilizam boas funções de avaliação.

O *simulated annealing* não escolhe o melhor movimento, gera um movimento aleatoriamente. Se ele for um movimento que melhora a situação atual, é executado. Caso contrário, o algoritmo faz um cálculo utilizando uma função exponencial que gera valores entre zero e um que representam a probabilidade de se fazer o movimento. Essa probabilidade varia de acordo com o grau de piora da solução com esse movimento. Quanto maior o grau de piora do movimento menor a probabilidade de ser realizado. *Annealing* (um termo próximo do conceito de têmpera) é o processo de mover o problema de um

estado de muita energia para um estado de pouca energia. No estado de alta energia os movimentos são feitos de forma a alcançarem mais rapidamente estados mais próximos à solução. Nos estados de baixa energia os movimentos são mais lentos e mais diversificados (Murray and Church, 1995). Por esse processo o agente consegue fugir dos máximos locais e chegar mais perto do ótimo global.

São parâmetros do *simulated annealing* a temperatura inicial que representa a energia, o tempo em iterações para trocar de temperatura e o quanto variar na temperatura. Tipicamente, os usuários dessa heurística (Morton e Pentico, 1996) preferem fazer menos movimentos que pioram a função que avalia o estado no início do processo e diversificar mais quando as melhorias não são mais tão acentuadas. Essa diversificação é conseguida buscando parâmetros que gerem probabilidades maiores para pioras maiores.

Como apresentado nas seções anteriores, a fuga dos máximo locais é essencial nas buscas heurísticas e cada proposta heurística possui suas estratégias diferenciadas com esse fim. As três heurísticas analisadas nessa seção se diferenciam exatamente na forma como fogem dos máximos locais.

Além das duas estratégias sistematizadas por Russel and Norvig (1995), Glover (1995) e Murray and Church (1995) descrevem a estratégia *Tabu Search*. A busca *Tabu* é baseada na premissa de que, um agente, para ser classificado como um agente inteligente, deve incorporar em sua busca uma memória adaptada ao momento e uma exploração responsável das opções de movimento. Possui técnicas, ainda, para escolher melhor as opções a serem exploradas, isto é, para escolher a vizinhança. Durante o processo, a busca *Tabu* classifica as opções que não serão exploradas e as coloca em uma lista chamada lista *Tabu*.

Para fugir dos ótimos locais, a busca *Tabu* usa a seguinte estratégia: faz os movimentos mesmo que sejam piores em termos da função objetivo. E, para garantir que os próximos movimentos não retornem ao mesmo máximo local,

guarda os últimos m movimentos em na lista *Tabu*. O agente não retorna a estes últimos movimentos, forçando, assim, o contorno do máximo local.

Morton e Pentico (1996) discutem a diferença entre movimentos de diversificação e movimentos de intensificação. Os movimentos de intensificação melhoram a função objetivo e levam o agente mais rapidamente em direção ao ótimo global, enquanto que os movimentos de diversificação contornam os máximos locais fazendo movimentos que pioram o valor da função objetivo.

Uma diferença importante entre as metodologias da busca *Tabu* e do *simulated annealing* é que o *Tabu* diversifica e força novas soluções ao impedir movimentos na lista *Tabu*, já o *simulated annealing* diversifica pela aleatoriedade dos movimentos (Morton e Pentico, 1996).

Comparando estas duas estratégias de diversificação com a estratégia usada pela Razão-R, vemos que a Razão-R força novos movimentos, como o *Tabu*, ao excluir temporariamente da busca os seus últimos movimentos na lista dos descartados. A busca *Tabu* mantém fixo o tamanho da lista enquanto que na Razão-R a lista cresce ao longo do caminho, mas, como considera que na lista das descartadas estão as prescrições com valores melhores, volta à lista de β em β iterações.

Tanto o *Tabu* como o *simulated annealing* geram aleatoriamente o estado inicial e não possuem um estado meta definido. A condição de terminação de ambos é determinada quando não se consegue mais melhorar a função objetivo significativamente. A função de avaliação pode variar de acordo com a necessidade do problema. Mas na Razão-R o estado inicial e o meta são definidos e muito importantes no contexto da heurística e, juntos com a função de avaliação, montam a lógica do caminho seguido pelo agente.

A terceira heurística a ser analisada é o algoritmo genético que simula o processo de evolução natural de uma população (Morton e Pentico, 1996). No contexto dos algoritmos genéticos existe uma população de possíveis soluções

para o problem. O objetivo é encontrar o melhor indivíduo da população. Nos problemas combinatoriais, para os quais não é impossível gerar todas as soluções e avaliá-las, são gerados aleatoriamente n indivíduos. Sobre esses indivíduos aplicam-se as leis naturais de mutação, *crossing-over* e seleção natural.

Se essa metodologia for aplicada ao problema em questão, cada cromossomo, que representa um indivíduo ou uma combinação, teria o tamanho da quantidade de unidades de produção e cada gen seria uma prescrição para essa unidade. A mutação ocorre aleatoriamente sobre a população e um gen é trocado. O *crossing-over* troca pedaços dos cromossomos e acontece aleatoriamente. Após a multiplicação, a seleção natural escolhe os melhores de acordo com uma função de avaliação que, como na busca *Tabu* e no *simulated annealing*, pode ser escolhida pelo implementador da heurística.

São parâmetros do algoritmo genético a quantidade de mutações, a quantidade de *crossing-over* e a quantidade de indivíduos com os quais se trabalha. De forma semelhante ao *simulated annealing* e o *Tabu*, o estado inicial é gerado aleatoriamente e a condição de parada é o momento no qual não mais se consegue melhoria significativa na função objetivo.

Em contraste com essas três heurísticas, a Razão-R começa com a função objetivo de valor máximo e permite piores consecutivas em direção ao estado meta. A consequência lógica dessa estratégia é que a Razão-R busca um caminho curto para a solução enquanto que todas as outras não se importam com o tamanho do caminho e quanto mais caminham mais melhoram a solução.

4.5 Conclusões da análise da Razão-R

Quando se analisam os conceitos que envolvem uma heurística, inseridos no contexto da teoria da Inteligência Artificial, desde abordagens mais antigas (Nilsson, 1982) até abordagens mais modernas como a de Russel e Norvig

(1995), verifica-se que a heurística da Razão-R está construída de acordo com tais conceitos.

A evolução da heurística da Razão-R, incluindo as modificações apresentadas neste trabalho, foram feitas com o objetivo de melhorarem a sua performance e precisão. É importante ressaltar que o estudo dos conceitos de inteligência artificial também inspiraram as melhorias na implementação.

As análises que inspiraram as melhorias contribuíram para a solução do problema florestal estudado e, ao mesmo tempo, para as pesquisas com buscas heurísticas. A experiência gerada pelas pesquisas com a Razão-R aqui apresentadas podem, por sua vez, inspirar outros construtores de soluções baseadas em heurísticas.

As constatações teóricas feitas no confronto da Razão-R com os princípios de inteligência artificial validam a heurística da Razão-R como um método promissor no contexto florestal e como solução a ser testada para problemas que se utilizem de formulações de programação inteira semelhantes.

Verifica-se, após análise da sua lógica, que a heurística da Razão-R pode ser utilizada com segurança na construção de um conjunto de soluções florestais para problemas com mais restrições, mais complexos e de soluções mais difíceis do que o modelo de problema considerado neste trabalho.

5 AVALIAÇÃO DO DESEMPENHO DA NOVA HEURÍSTICA DA RAZÃO-R

5.1 Análise do desempenho

As melhorias feitas na heurística, a partir do estudo teórico dos conceitos de inteligência artificial e da análise da implementação anterior da Razão-R, são avaliadas neste capítulo. Apresentam-se também os conceitos utilizados na avaliação, os problemas usados nos testes e a metodologia dos testes.

5.1.1 Os elementos avaliados

Para atender ao segundo grupo de objetivos deste trabalho foi montando um ambiente de testes em *Pascal* (Delphi 4) que permitiu a análise de 14 problemas definidos na seção 5.1.3. Nesse ambiente de testes foram avaliados os seguintes elementos:

(i) Tempo de cada iteração

Uma das melhorias mais significativas feitas com o objetivo de diminuir o tempo computacional da heurística envolveu mudanças na base de representação. Para avaliar essa melhoria, mediu-se o tempo médio de uma iteração e compararam-se os resultados com as medidas obtidas para implementações anteriores da Razão-R. O tempo de uma iteração é diretamente relacionado com o tamanho do problema, pois a análise em cada iteração envolve tantas prescrições quantas forem as não-selecionadas e/ou descartadas nesse momento.

(ii) Fuga dos máximos locais

Para permitir condições de fuga de máximos locais, foi criada uma rotina *batch*, através da qual foi possível a execução da heurística para grandes

intervalos dos parâmetros α e β . Avalia-se neste caso o número de iterações como uma *proxy* para o custo da heurística, e o valor da função objetivo da solução final para cada par de valores (α, β) .

(iii) A eficácia da heurística

As rotinas básicas da heurística foram alteradas, os algoritmos foram otimizados, e principalmente, foram criadas regras de desempate na escolha do guia dos movimentos. O objetivo dessas alterações foi alcançar maiores valores de TPV, isto é, chegar mais perto do ótimo matemático. Compararam-se os melhores valores da função objetivo obtidos pela heurística da Razão-R com os valores ótimos obtidos para a formulação inteira dos problemas menores, resolvidos pelo algoritmo *branch-and-bound*, e para a formulação não inteira dos problemas maiores, resolvidos pelo método *simplex*.

Segundo Chiavenato (1987), a eficácia é uma medida de alcance de resultados, enquanto que eficiência é uma medida de utilização dos recursos disponíveis durante esse processo. Seguindo esse conceito da administração, a eficácia da heurística pode ser entendida como uma medida que representa a distância entre o resultado obtido e o melhor resultado possível de ser encontrado por outros métodos. Enquanto que a eficiência da heurística pode ser vista como uma medida dos recursos computacionais gastos para alcançar os resultados. Descreve-se nessa seção como se calcula a eficácia da heurística e na seção seguinte a eficiência.

A eficácia é determinada pela razão expressa em porcentagem entre o melhor TPV encontrado e o ótimo matemático. Como não é possível encontrar o ótimo matemático inteiro para os problemas maiores, calculou-se a eficácia nesses casos em função do ótimo contínuo.

Morton e Pentico (1996) estudaram várias heurísticas e aplicações diferentes, em cerca de 1000 problemas, e chegaram a soluções que em média

ficaram a 0.5% do ótimo, com um máximo de 3%. Estes valores são usados como referência para os valores obtidos com a Razão-R.

A melhoria da eficácia é avaliada através de uma comparação com as porcentagens do ótimo verificadas em versões anteriores.

(iv) A eficiência da heurística

Os parâmetros α e β e o número de iterações são usados no cálculo da *penetrance*, conceito sugerido por Russel e Norvig (1995) para avaliação da eficiência de uma busca heurística em profundidade. Este critério é apresentado em mais detalhes na próxima seção.

O conceito de complexidade de espaço também definido por Russel e Norvig (1995) avalia a dimensão do espaço do problema, e juntamente com a *penetrance*, auxilia a análise da eficiência da heurística.

(v) Condições de interrupção

A investigação das condições de interrupção envolveu parâmetros gravados nos arquivos de *log* criados para essa finalidade.

A utilização dos critérios acima permitiu verificar as características que, segundo Russel e Norvig (1995), devem ser avaliadas ao analisar a estratégia de um agente inteligente de busca heurística:

- Complexidade de tempo; o tempo de cada iteração, a eficiência da heurística, e as condições de interrupção;
- Complexidade de espaço; a própria complexidade e a eficiência com o aumento da complexidade;
- Otimidade; a eficácia da heurística comparando-se os resultados com os ótimos matemáticos.

5.1.2 Medidas de desempenho

(i) Penetrance

Penetrance é uma medida de eficiência de heurística definida por Russel e Norvig (1995) e Nilsson (1982) dada por:

$$P = \frac{I}{E}$$

Onde:

I = iterações da melhor solução encontrada pela heurística;

E = número de nós expandidos durante a busca

Consideraram-se como nós expandidos todas as opções pesquisadas quando a busca é feita no grupo das prescrições não selecionadas, já que, as buscas nos descartados são feitas sobre opções que já foram avaliadas anteriormente.

Considerou-se também que, mesmo que as opções de prescrições já tenham sido analisadas em iterações anteriores, a troca com qualquer uma das prescrições analisadas sobre o estado atual se configura em um novo estado.

Sendo R o número de regimes e U o número de unidades de produção, apresenta-se a seguir a quantidade de opções pesquisadas a cada iteração:

1ª Iteração	$(R - U) - 1$
2ª Iteração	$(R - U) - 2$
3ª Iteração	$(R - U) - 3$
...	
nª iteração	$(R - U) - n$

Sendo I' o número de iterações ocorridas nos não-selecionados, o total de opções pesquisadas nas I' iterações é:

$$E = \sum_{n=1}^{I'} ((R-U) - n) = (R-U)I' - \frac{I'(I'+1)}{2}$$

O cálculo de I' , por sua vez, é obtido com o auxílio dos parâmetros α e β usados na melhor solução encontrada. I' é o total de iterações menos as iterações feitas sobre os descartados, a saber:

$$I' = I - 1 - \frac{(I - \alpha)}{\beta}$$

(ii) Complexidade de espaço

A complexidade de espaço expressa a idéia da quantidade máxima de estados que podem ser investigados pelo agente. A complexidade é calculada multiplicando-se o número máximo de iterações pela quantidade máxima de estados que poderia ser calculada em cada iteração.

A quantidade de iterações máxima é dada pela soma da quantidade máxima de iterações possíveis de serem feitas nos não-selecionados mais o número de iterações feitas nos descartados durante o processo de busca.

Nos não-selecionados, o agente pode fazer no máximo a quantidade de prescrições existentes no problema, já que a cada busca nos não-selecionados o agente passa uma prescrição para o grupo dos descartados. Enquanto que a quantidade de iterações que o agente busca nos descartados depende dos parâmetros α e β .

Portanto a complexidade (O) é dada por:

$$O = (R + \frac{R - \alpha}{\beta} + 1)(R - U)$$

onde: R - Número de prescrições ou número de variáveis inteiras do problema

U - Número de unidades de produção
 α e β - os parâmetros da heurística

Uma determinada estratégia de busca da heurística da Razão-R, por exemplo um par $[\alpha, \beta]$, precisa ser escolhida para o cálculo da complexidade. Foi escolhida a estratégia de maior custo para a qual a heurística encontrou uma solução. Com a escolha dessa estratégia pode-se comparar a complexidade com o número efetivo de nós expandidos na estratégia mais difícil para o agente dentre as testadas.

5.1.3 Problemas usados nos testes

Foram montados quatro grupos de problemas para serem usados nos testes. Os problemas foram batizados *Euca*, *Modelo*, *Apache* e *Minesota*. Os quatro grupos se constituem em variações de problemas já testados com versões anteriores da Razão-R, e totalizam quatorze problemas.

Os problemas *Euca*, *Apache* e *Minesota* são descritos em Rodriguez (1994) e o problema *Modelo* é apresentado em Rodriguez (1999). Os quatro grupos de problemas são representativos da realidade florestal para a qual a heurística se destina.

Os problemas *Euca* e *Modelo* representam florestas de eucalipto cujas alternativas de manejo envolvem variações e combinações de diferentes idades de corte. O valor de cada alternativa, usado como coeficiente da função objetivo, é o valor presente líquido da alternativa. Com a finalidade de obter problemas semelhantes e do mesmo tamanho, criaram-se novos problemas alterando-se o número de unidades de produção e mudando-se o valor dos coeficientes da função objetivo para a soma dos volumes obtidos ao longo do horizonte de planejamento pelos respectivos regimes.

O problema *Apache* foi gerado em um projeto para o Bureau of Indians

Affairs – Fort Apache Agency coordenado por Rodriguez (1994). O problema Minesota foi gerado baseado em modelos de crescimento para 14 tipos de florestas propostos por Walters e Ek (1993). A quantidade de unidades de cada tipo, o tamanho de cada unidade e as idades iniciais de cada unidade foram geradas randomicamente. A Tabela 1 mostra os problemas e suas características relevantes para os testes.

TABELA 1 – Características básicas dos problemas usados nos testes da heurística da Razão-R

Problema	Número de Variáveis	Número de Unidades de Produção	Número de Períodos	Restrição de Produção por Período	Tipos de Coeficientes na Função Objetivo
Euca1	100	20	21	5000	VPL
Euca2	155	30	21	8000	VPL*
Euca3	100	20	21	5000	Volume
Euca4	155	30	21	8000	VPL
Modelo1	288	32	21	18000	VPL*
Modelo2	288	32	21	19000	VPL*
Modelo3	288	32	21	18000	VPL
Modelo4	288	32	21	19000	VPL
Apache1	2584	152	15	10000000	VPL
Apache2	2584	152	15	12000000	VPL
Apache3	2584	152	15	10000000	VPL*
Minesota1	605	70	15	4000000	VPL
Minesota2	17620	2102	15	115000000	VPL
Minesota3	17620	2102	15	121000000	VPL

Na Tabela 1, a coluna "tipo de coeficientes" mostra o método usado para o cálculo dos coeficientes da função objetivo, o indicativo "VPL" significa que foram usados os coeficientes do problema original, o indicativo "VPL*" indica que os coeficientes foram ligeiramente alterados, e "Volume" significa que os

coeficientes foram calculados com base na soma de volumes produzidos ao longo do horizonte de planejamento.

5.1.4 Metodologia dos testes

Utilizando o recurso de processamento *batch*, para cada um dos problemas, foram testados grandes intervalos de α e β . O valor inicial 2 foi usado para ambos os parâmetros em todos os problemas. Para cada par $[\alpha, \beta]$ mediu-se: o número de iterações, tempo, TPV final, déficit final. A Tabela 2 mostra os valores dos parâmetros para os problemas testados.

TABELA 2 – Parâmetros α e β para os problemas testados

Problema	Valor máximo para α	Intervalo de variação de α	Valor máximo para β	Intervalo de variação de β	Número máximo de iterações permitidas
Euca1	40	1	20	1	744
Euca2	40	1	20	1	757
Euca3	40	1	20	1	744
Euca4	40	1	20	1	741
Modelo1	40	1	20	1	813
Modelo2	40	1	20	1	801
Modelo3	40	1	20	1	631
Modelo4	40	1	20	1	632
Apache1	420	1 (02 a 20) 10 (20 a 420)	250	1 (02 a 20) 5 (20 a 100) 10 (100 a 250)	1607
Apache2	100	1 (02 a 20) 10 (020 a 100)	100	1 (02 a 20) 10 (20 a 100)	1001
Apache3	212	1 (02 a 20) 5 (020 a 100) 10 (100 a 200)	202	1 (02 a 20) 5 (20 a 100) 10 (20 a 250)	896
Minesota1	360	1 (02 a 10) 2 (010 a 360)	350	1 (02 a 10) 2 (010 a 350)	6878
Minesota2	260	1 (02 a 10) 10 (010 a 260)	210	1 (02 a 10) 10 (010 a 210)	304
Minesota3	100	1 (02 a 10) 10 (010 a 100)	100	1 (02 a 10) 10 (010 a 100)	252

Devido aos altos custos das análises de problemas maiores, foram geradas para estes problemas menos estratégias usando intervalos maiores para os parâmetros α e β . À medida que os testes foram sendo realizados, e as tendências verificadas, os testes se concentravam em intervalos que apresentassem maior variação nos resultados. Os testes foram feitos em um microcomputador com processador Pentium de 133 Mhz.

5.2 Resultados e discussão da avaliação de desempenho

(i) Tempo de cada iteração

Rodriguez e McTague (1997) apresentaram o resultado dos testes para uma implementação anterior da heurística da Razão-R. A Tabela 3 mostra os tempos médios por iteração obtidos. Na segunda coluna da tabela, estão os problemas semelhantes para os quais devem ser comparados os tempos por iteração.

O tempo calculado por Rodriguez e McTague (1997) foi a média de todos os testes feitos com várias estratégias α e β em microcomputador com processador Pentium de 100 Mhz. É importante considerar que os problemas usados por esses autores são os mesmos problemas dos quais os problemas testados no presente trabalho se originam.

TABELA 3 – Tempos obtidos nos testes da heurística da Razão-R apresentados por Rodriguez e McTague (1997)

Problema	Problemas Semelhantes	Número de Unidades	Número de Variáveis	Número Médio de Iterações	Tempo Médio (segundos)
1	Euca 1 – 3	20	100	58,1	0,35
2	Euca 2 – 4	30	150	103,3	0,50
3	Minesota 1	70	650	122,5	0,80
4	Apache 1 – 2 - 3	152	2584	585,3	4,10

A pior situação de tempo médio por iteração para a Razão-R é aquela em que o número de iterações é menor. Isto ocorre porque as primeiras iterações são mais longas devido a quantidade de regimes não-selecionados analisados. À medida que o agente avança na busca, as prescrições são transferidos para o grupo dos descartados em que são feitas buscas de β em β iterações apenas, sobrando cada vez menos iterações no grupo dos não-selecionados para serem calculadas. Por esse motivo, foi escolhida, dentre as estratégias calculadas, aquela em que o agente levou menos iterações para encontrar uma solução. Os tempos médios obtidos estão mostrados na Tabela 4.

TABELA 4 – Resultados: Tempos médios por iteração obtidos nos testes da versão atual da heurística da Razão-R.

Problema	Número de Unidades	Número de Variáveis	Número de Iterações	Tempo Total (segundos)	Tempo Médio (segundos)
Euca1	20	100	41	<1	<0,001
Euca2	30	155	66	<1	<0,001
Euca3	20	100	42	<1	<0,001
Euca4	30	155	59	<1	<0,001
Modelo1	32	288	83	1	0,012
Modelo2	32	288	83	1	0,012
Modelo3	32	288	83	<1	<0,001
Modelo4	32	288	83	<1	<0,001
Apache1	152	2584	1008	67	0,066
Apache2	152	2584	887	72	0,081
Apache3	152	2584	885	56	0,063
Minesota1	70	605	143	3	0,021
Minesota2	2102	17620	3599	1172	0,326
Minesota3	2102	17620	3853	2276	0,591

Verifica-se nos problemas Euca e Modelo 3 e 4 que o tempo total das iterações foi inferior a 1 segundo. É importante salientar que para esses

problemas pequenos o tempo total foi inferior a um segundo para todas as estratégias calculadas.

Os problemas Modelo1 e Modelo2 de 288 variáveis apresentaram um tempo médio por iteração de 0,012 segundos, que é cerca de 40 vezes menor que o tempo obtido por Rodriguez e McTague (1997) no Problema 2 de 150 variáveis.

No Problema Minnesota1 a Razão-R atual obteve um tempo médio de 0.07 segundos, 38 vezes menor que o anterior para o problema 3. No Problema Apache 1, 2 e 3 o tempo verificado foi, em média, 58 vezes menor.

Mesmo considerando que o computador utilizado no presente trabalho é ligeiramente mais rápido que o computador utilizado nos testes em 1997, a pequena melhoria de hardware não justificaria a grande melhoria obtida nos tempos por iteração.

Conclui-se que o tempo por iteração melhorou significativamente na nova versão da Razão-R, confirmando a hipótese levantada de que a alteração na base de representação melhoraria o tempo por iteração ao diminuir a quantidade de operações realizadas pelo agente na escolha do próximo estado.

(ii) Fuga dos máximos locais

Os resultados dos testes das estratégias de fuga dos máximos locais estão apresentados resumidamente na Tabela 5 e apresentados com detalhes no Apêndice A.

A Tabela 5 mostra a melhor solução encontrada pelo agente Razão-R dentre todas as estratégias de fuga testadas. As colunas α e β se referem à estratégia de fuga que levou à melhor solução; os valores da coluna “% do ótimo contínuo” referem-se à porcentagem do TPV obtido pelo agente em relação ao ótimo matemático contínuo obtido com algoritmo *simplex*.

Verifica-se que as melhores soluções para todos os problemas foram

encontradas para β menor que 8. Essa foi uma constatação interessante porque Rodriguez e McTague (1997) apresentaram testes com as estratégias α e β , mas observaram esse fato apenas para os problemas 1, 2 e 3. Esse fato também não foi observado no problema 4 testado na ocasião, nem nos testes feitos por Rodriguez (1999) para os problemas Modelo.

Isso ocorreu nos testes de Rodriguez e McTague (1997) porque apenas o valor $\beta=5$ e valores maiores que 10 foram testados para o problema 4. E nos testes de Rodriguez (1999) foram testados apenas valores de $\beta>9$. Ocorria que para problemas maiores os testes eram feitos com valores maiores .

Os melhores valores de β não se alteram com o tamanho do problema. Esse fato pode ser notado na Tabela 5.

TABELA 5 – Parâmetros das melhores estratégias de fuga dos máximos locais para cada problema testado.

Problema	α	β	% do Ótimo Contínuo
Euca1	22	2	98,4
Euca2	27	2	99,2
Euca3	13	7	99,3
Euca4	30	2	99,1
Modelo1	16	5	99,9
Modelo2	25	6	99,9
Modelo3	25	6	99,9
Modelo4	16	5	99,9
Apache1	9	3	99,4
Apache2	9	3	99,7
Apache3	20	3	98,5
Minesota1	9	3	99,6
Minesota2	190	6	99,8
Minesota3	70	5	99,7

Nos gráficos e tabelas apresentados no Apêndice A verifica-se uma tendência de melhores soluções para β menor que 10.. Os valores de α também não variam de forma crescente com o tamanho do problema, mas como os maiores valores, os únicos maiores que 30, foram observados nos grandes problemas, não se pode concluir com certeza que α seja independente do tamanho do problema.

A Tabela 1A, apresentada no Apêndice A, mostra que as melhores soluções estão entre as de menor custo. Mais especificamente, o número de iterações das melhores soluções é muito próximo do número de iterações da solução de menor custo.

O inverso também é verdadeiro: as soluções de menor custo encontram soluções muito próximas das melhores soluções. Mais especificamente, a porcentagem do ótimo das soluções de menor custo é muito próxima da encontrada nas melhores soluções. Para os problemas Modelo3 e Modelo4 os valores de TPV são iguais, e todos os outros valores se aproximam em torno de 0.5%.

Observa-se também na Tabela 1A do Apêndice A, que a maioria dos valores de β são pequenos para as soluções de menor custo.

Valores baixos de β significam um retorno mais freqüente do agente ao grupo dos descartados. Isto é, o agente volta mais vezes ao grupo de regimes em que estão os regimes de maior valor.

O fato de se conseguir fugir dos máximos locais eficientemente pode ser explicado usando o conceito de diversificação apresentado por Morton e Pentico (1996) na análise dos algoritmos iterativos de melhoria. Quando o agente avalia mais freqüentemente opções no grupo dos descartados, quebra-se a tendência que estava sendo traçada pelas escolhas nos não-selecionados e, portanto, diversifica-se mais a estratégia de busca.

Conclui-se sobre as estratégias de fuga de máximos locais que:

- as melhores soluções estão entre as de menor custo, o que está de acordo com a lógica da Razão-R que busca o menor caminho entre o estado inicial e o estado meta;
- a melhor forma de fugir dos máximos locais é fazer buscas freqüentes no grupo dos descartados.

Entretanto, observou-se também que a estratégia de fuga influencia o número de vezes em que o agente não atinge o estado meta. A Tabela 6 mostra dados sobre as estratégias para as quais o agente não encontra solução. Os valores da coluna “% Sem solução” se referem porcentagem das estratégias calculadas para as quais o agente não encontrou solução. A coluna “% $\beta > 10$ ” apresenta as porcentagem das estratégias sem solução que tem $\beta > 10$. Verifica-se que a maioria das estratégias sem solução têm $\beta > 10$. Isto também é válido para α .

TABELA 6 – Estratégias para as quais o agente não encontra solução.

Problema	% Sem Solução	% $\beta > 10$	% $\alpha > 10$
Euca1	23,8	63,8	69,5
Euca2	47,2	65,0	65,0
Euca3	48,5	82,0	83,1
Euca4	43,3	69,8	72,3
Modelo1	8,2	32,8	59,7
Modelo2	17,6	73,0	72,3
Modelo3	17,4	90,0	82,7
Modelo4	4,1	92,3	84,6
Apache1	16,2	100,0	99,2
Apache2	7,4	100,0	93,2
Apache3	16,6	100,0	97,3
Minesota1	8,4	79,7	93,8
Minesota2	11,5	74,3	60,0
Minesota3	34,9	69,3	60,2

Não encontrar solução na implementação atual da Razão-R significa que o agente faz buscas no grupo das prescrições não-selecionadas até esgotá-lo, isto é, até todas passarem para o grupo das descartadas. Mas nos problemas mais fáceis, para os quais o agente encontrou soluções para todas as estratégias, o cálculo foi feito considerando as estratégias que resultavam em caminhos mais longos que a maioria das estratégias.

Verificou-se nos resultados dos testes que esse fato ocorreu no problema Minnesota1 para qual o agente encontrou solução para todas as estratégias. Um grupo de estratégias de custo alto foi escolhido para representar o grupo de estratégias sem solução não existente no problema.

O que se conclui é que a ação do agente é facilitada quando o valor de β é baixo, tanto para encontrar melhores soluções, como para encontrar o caminho que leva às soluções. Isso pode ser explicado novamente com o auxílio do conceito de diversificação: a diversidade de opções é maior quando o agente volta mais vezes ao grupo dos descartados.

O fato de os valores de α pequenos também facilitarem ao agente encontrar soluções pode ser visto como o agente entrando em processo de diversificação mais cedo na busca. Se esse processo é iniciado mais cedo, pode evitar que o agente se afaste do estado meta.

(iii) A eficácia da heurística

A eficácia obtida na versão atual foi comparada com a eficácia obtida por Rodriguez (1994) e Rodriguez e McTague (1997) em versões anteriores. A Tabela 7 mostra os resultados das versões anteriores.

TABELA 7 – Resultados de eficácia da Razão-R observados nos testes das versões anteriores.

Problema	Problemas Semelhantes	Número de Unidades	Número de Variáveis	% do Ótimo contínuo	% do Ótimo inteiro
1994					
Euca	Euca 2 - 4	30	155	96,20	96,92
Apache	Apache1 - 2 - 3	152	2584	94,14	94,27
Minesota	Minesota 2 - 3	2102	17620	99,62	
1997					
1	Euca 1 - 3	20	100		99,6
2	Euca 2 - 4	30	150		99,4
3	Minesota 1	70	650	98,8	
4	Apache1 - 2 - 3	152	2584	97,7	

A segunda coluna da Tabela 7 apresenta os problemas com os quais devem ser comparados os resultados das versões anteriores.

A Tabela 8 mostra as melhores soluções encontradas pela Razão-R nas estratégias testadas na versão atual.

Verificou-se que, para todos os tamanhos de problema, a eficácia aumentou, comprovando a importância das melhorias realizadas. As menores melhorias ocorreram nos problemas grandes, pois a eficácia já era muito alta.

Verifica-se que os valores relativos aos ótimos inteiros são superiores a 99,6%, chegando a 0,5% do ótimo como nos testes de Morton e Pentico (1996). Para o grupo Minesota os valores relativos aos ótimos contínuos também são superiores a 99,6%. Seriam maiores se comparados aos valores ótimos inteiros (desconhecidos), e também alcançariam o mesmo bom desempenho citado por Morton e Pentico (1996).

TABELA 8 - Resultados de eficácia dos testes realizados com a versão atual da heurística.

Problema	Número de Unidades	Número de Variáveis	% do Ótimo Contínuo	% do Ótimo Inteiro
Euca1	20	100	98,40	99,90
Euca2	30	155	99,21	99,85
Euca3	20	100	99,28	99,69
Euca4	30	155	99,10	99,84
Modelo1	32	288	99,88	99,94
Modelo2	32	288	99,90	99,97
Modelo3	32	288	99,91	99,99
Modelo4	32	288	99,90	99,96
Apache1	152	2584	99,39	
Apache2	152	2584	99,71	
Apache3	152	2584	98,47	
Minesota1	70	605	99,61	
Minesota2	2102	17620	99,84	
Minesota3	2102	17620	99,73	

Apenas para o grupo de problemas Apache, não se verificam valores superiores a 99,5%. Mas considerando-se a mesma variação de valores entre as porcentagens do ótimo contínuo e para o ótimo inteiro, apenas para o problema Apache 3 a Razão-R não apresentaria distância do ótimo inferior a 0.5%. Mesmo assim, esse valor não seria superior ao máximo de 3% sugerido por Morton e Pentico (1996).

Verifica-se também que, na versão nova, não existe mais a tendência de maior eficácia nos problemas maiores. Pode-se observar mais claramente, através do gráfico da Figura 4.

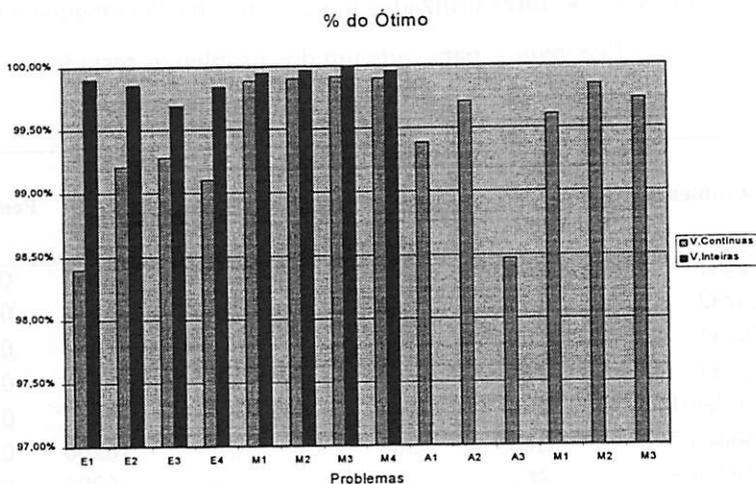


FIGURA 4 – Eficácia obtida nos testes com a Razão-R

As versões anteriores eram mais eficazes para os problemas maiores pois oferecem mais opções de caminho para o agente. Mas, agora, com as melhorias implementadas, esse fato não mais influencia na eficácia. A eficácia se tornou excelente para todos os tamanhos de problema, confirmado a hipótese de que as melhorias feitas baseadas em conceitos teóricos e análise da implementação anterior melhoram a eficácia da Razão-R.

(iv) A eficiência da heurística

A eficiência foi analisada com base nos conceitos *penetrance* e *complexidade*. Os valores de *penetrance* e os valores intermediários usados nos cálculos são apresentados na Tabela 9.

TABELA 9 – Valores utilizados nos cálculos da *Penetrance* e valor da *Penetrance* para cada um dos problemas testados

Problema	Número de Variáveis	Iterações para a Melhor Solução	Visitas ao Grupo dos Não Selecionados	Nós Expandidos	Penetrance
Euca1	100	50	35	2188	0,022857
Euca2	155	90	58	5534	0,016262
Euca3	100	53	46	2632	0,020139
Euca4	155	99	64	5921	0,016719
Modelo1	288	102	84	17942	0,005685
Modelo2	288	85	74	16206	0,005245
Modelo3	288	85	74	16206	0,005245
Modelo4	288	102	84	17942	0,005685
Apache1	2584	1137	760	1559520	0,000729
Apache2	2584	918	614	1304750	0,000704
Apache3	2584	1222	820	1658577	0,000737
Minesota1	605	169	115	54772	0,003085
Minesota2	17620	3680	3097	43267682	0,000085
Minesota3	17620	4204	3376	46692508	0,000090

Pelo conceito de *penetrance* percebe-se que quanto menor o valor obtido, maior é a eficiência do agente. A Razão-R se mostrou muito mais eficiente para os maiores problemas, o que é uma característica desejável pois os problemas reais são maiores ou iguais ao maior problema testado. Percebe-se também que, para os problemas de mesmo tamanho, a *penetrance* é da mesma ordem de grandeza.

Pela análise da *complexidade* de espaço percebe-se a mesma tendência. A Tabela 10 mostra os resultados obtidos. A coluna “nós expandidos” contém os nós expandidos na solução de maior custo encontrada pela Razão-R. Essa é a solução, dentre as estratégias testadas, em que o agente encontrou a solução com mais iterações.

A última coluna da Tabela 10 mostra a razão entre a quantidade de nós

expandidos e a quantidade máxima de nós que poderiam ser expandidos pelo agente, dando uma idéia do percentual do espaço explorado pelo agente até encontrar a solução no pior dos casos.

TABELA 10 – Valores utilizados no cálculo da Complexidade de Espaço e Complexidade de Espaço para cada um dos problemas testados

Problema	Variáveis	Nós Expandidos	Complexidade	Solução / Complexidade
Euca1	100	8080	10213	79%
Euca2	155	19500	21114	92%
Euca3	100	8080	8424	96%
Euca4	155	22875	23906	96%
Modelo1	288	62720	80819	78%
Modelo2	288	64256	82752	78%
Modelo3	288	64256	82752	78%
Modelo4	288	62720	80819	78%
Apache1	2584	5972992	8991104	66%
Apache2	2584	6235648	8320683	75%
Apache3	2584	6162688	9185664	67%
Minesota1	605	179225	336453	53%
Minesota2	17620	77605518	307601676	25%
Minesota3	17620	77605518	307582278	25%

Na medida em que o tamanho do problema aumenta, o agente explora uma quantidade de nós proporcionalmente menor até encontrar a solução. O que é uma característica muito importante e desejável em uma heurística, mostrando a eficiência da função de avaliação como guia dos movimentos do agente.

Concluiu-se que, com base nos critérios de *penetrance* e *complexidade*, a Razão-R é mais eficiente quanto maior o problema. Essa característica garante o bom comportamento da heurística, mesmo com os tempos ainda longos, cerca de 40 minutos para a solução do maior problema testado neste trabalho. Tem-se a certeza de que o custo computacional não crescerá exponencialmente com o

aumento do tamanho do problema.

O gráfico da Figura 5, no qual os problemas estão ordenados pelo número de variáveis, mostra claramente essa característica da Razão-R. À medida em que a complexidade de espaço aumenta, a heurística é mais eficiente.

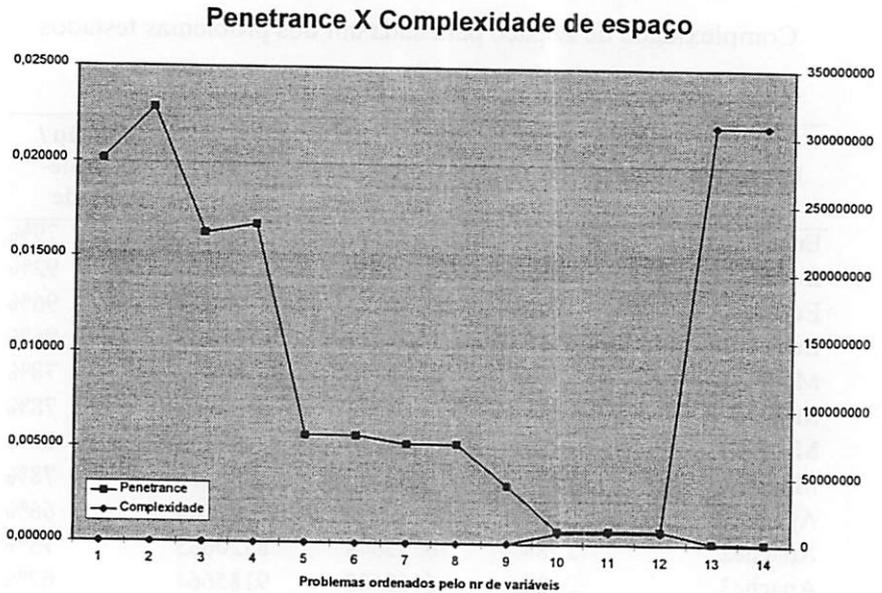


FIGURA 5 – Penetrance X Complexidade de Espaço

(v) Condições de interrupção

Os dados apresentados na Tabela 1A do Apêndice A, mostram que, da mesma forma como as melhores soluções estão próximas das soluções de menor custo, as piores soluções estão próximas das soluções de maior custo. Soluções de maior custo são as soluções envolvendo um número maior de iterações.

No Apêndice A estão também os gráficos de Iterações X TPV que foram feitos para todos os problemas, nos quais destacam-se dois pontos importantes:

- i) quanto maior o número de iterações menor o TPV obtido pelo agente, resultado coerente com o observado nos dados da Tabela 1A.

ii) inicialmente aglomerados, os pontos se tornam mais difusos conforme aumenta o número de iterações.

Os problemas Minesota2 e Minesota3 são diferentes apenas nas restrições anuais de produção, que são mais restritivas para o Minesota3. O mesmo ocorre entre os problemas Modelo3 e Modelo4. Os números de iterações da melhor solução e da solução de menor custo para os problemas com restrições mais difíceis são maiores. Como o estado inicial é o mesmo para ambos os problemas e o número de iterações é maior para os problemas mais difíceis, verificou-se que o agente precisou percorrer um caminho mais longo no sentido de atender às restrições mais difíceis.

Verificou-se, portanto, que o número de iterações não varia apenas com o tamanho do problema, como pode ser observado claramente nos dados, mas varia também em função do tamanho e da dificuldade para se atenderem os limites de produção impostos nos problemas.

Ao iniciar a resolução de um problema, entretanto, a dificuldade para atingir as metas não é conhecida. Conhece-se apenas o seu tamanho. A definição de um critério de interrupção não se pode basear apenas no número de iterações, mesmo sabendo-se que existe um ponto a partir do qual a busca não é mais compensatória.

A condição de interrupção com base no número de iterações poderia ser um parâmetro opcional. Seria ligado a partir de um certo ponto na análise, quando o problema já se torna mais previsível, ou para problemas semelhantes com número de iterações limite já conhecido.

Observando os *logs* criados durante as análises para as estratégias nas quais o agente não encontrou solução, nota-se que o déficit permanece baixo por algum tempo, não atingindo a meta Déficit=0. Em alguns casos o déficit volta a subir, em outros as opções de busca terminam com o déficit ainda baixo.

Na Figura 6 é possível ver o comportamento da heurística através do

gráfico de déficits de uma estratégia sem solução.

Sugere-se a criação de uma condição de interrupção sensível ao comportamento da evolução na redução do déficit. Desta forma, se o déficit não diminuir em n iterações, o processo é interrompido. Neste caso, n seria um parâmetro a ser testado nas próximas implementações.

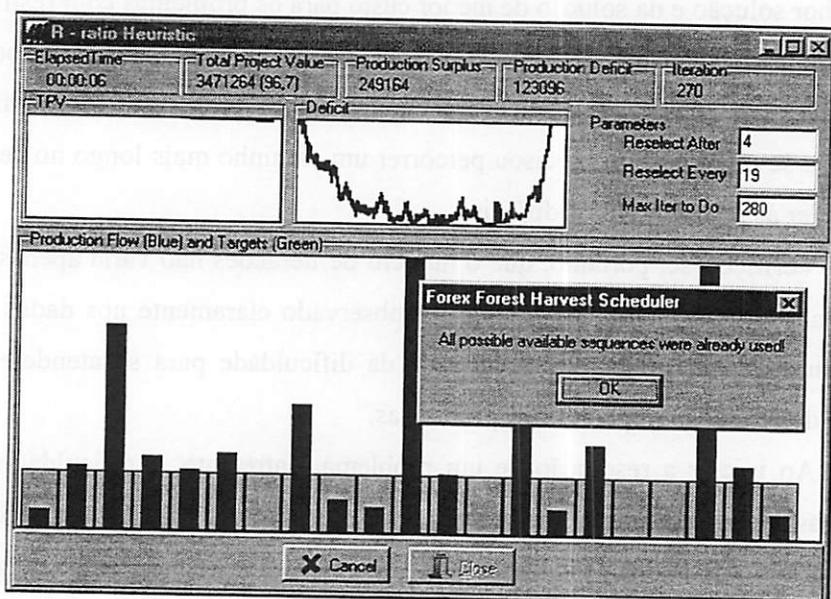


FIGURA 6 – Comportamento do Déficit em estratégias sem solução

Um outro ponto observado durante a execução das muitas estratégias testadas foi que em muitos casos o déficit não atinge o valor zero, mas chega muito perto dele, e permanece próximo a zero durante muitas iterações. Essa seria também uma condição de interrupção interessante, principalmente para problemas de grande porte.

Quando as metas de produção anuais são muito altas, a busca de déficit zero poderia ser redefinida como uma busca por déficit próximo a zero. A distância do valor zero e o número de iterações em que o agente permanece a

essa distância do zero poderiam também ser interpretados como os novos parâmetros a serem testados em implementações futuras.

Citam-se, portanto, três grupos de novos parâmetros baseados em:

- i) número de iterações limite;
- ii) número de iterações sem que o agente consiga melhorar a solução;
- iii) número de iterações em que o agente permanece próximo ao déficit zero.

4.

CONCLUSÕES E CONSIDERAÇÕES FINAIS

O esforço de pesquisa na busca de soluções eficientes para o problema básico de gestão florestal apresentado neste trabalho utiliza como ferramentas básicas a Tecnologia de Informação e a Pesquisa Operacional. A heurística da Razão-R foi proposta nesse contexto de pesquisa em 1994, quando as buscas heurísticas começaram a se disseminar na área florestal como método promissor para solucionar complexos problemas logísticos e de produção.

Desde então, a Razão-R tem sido estudada e aprimorada. O presente trabalho se propôs a contribuir para o avanço das pesquisas com essa heurística confrontando-a com os princípios de inteligência artificial.

A argumentação baseou-se na premissa de que a heurística da Razão-R foi construída seguindo os princípios básicos de inteligência artificial e que, portanto, teria potencial para realizar buscas eficientes e eficazes.

Destacam-se dentre os princípios analisados:

- o fato de a heurística da Razão-R possuir os seguintes elementos de um sistema de inteligência artificial bem definidos e claros: a base de representação, as regras de produção e o sistema de controle;
- a proposição de uma lógica de estados inicial e final, e a orientação dos movimentos com base em uma função de avaliação de baixo custo;
- a utilização de uma função de avaliação com memória (baseada em informações do problema);
- a composição de estratégias de busca apropriadas, com profundidade adequada ao problema combinatorial cujo universo de busca é muito grande;
- a adoção da estratégia típica de um *problem-solver agent*, que identifica claramente os seguintes elementos: o estado inicial, a função de sucessão, a função de teste de terminação e a função de custo do caminho;

- o fato de possuir a característica desejável de uma busca avarenta (*greedy search*), que encontra soluções com poucas iterações, e de uma busca A*, que considera também o custo da busca.

A maior qualidade da Razão-R, entretanto, reside no fato de a sua lógica de construção ser simples e ao mesmo tempo consistente: o agente parte da melhor posição e, no sentido de atender a todas as restrições do problema, busca o melhor e mais rápido caminho que menos se afaste da situação inicial.

Durante a comparação da lógica da heurística da Razão-R com os princípios de Inteligência Artificial, e da análise da sua implementação, foram introduzidas melhorias que seguem diversas recomendações encontradas na literatura especializada. A base de representação foi profundamente alterada, foram criadas regras de desempate, foram introduzidas rotinas que possibilitaram os testes das estratégias de fuga de ótimos locais, foram revistos e otimizados os algoritmos, e foi criado um novo conjunto relacional de dados para armazenar resultados e outras informações que permitem a avaliação posterior de desempenho das estratégias de solução dos problemas.

Em seguida, a heurística da Razão-R foi testada visando a avaliação do efeito das melhorias propostas com base em parâmetros também propostos pela Inteligência Artificial.

Verificou-se através dos testes que o tempo computacional foi reduzido em cerca de 40 vezes, que a eficácia da heurística se manteve para todas as dimensões de problema testados, e que a eficiência medida de acordo com o conceito de *penetrance* é alta principalmente para os problemas de grande porte.

As estratégias de fuga de ótimos locais foram testadas e os intervalos dos parâmetros da heurística da Razão-R que contribuem para uma fuga mais eficiente foram definidos.

O trabalho propõe também mecanismos de interrupção da busca se existirem evidências de que o agente está encontrando dificuldades para chegar a

uma solução. O mecanismo proposto se baseia no número de iterações para as quais não ocorrem mudanças no atendimento das restrições do problema, e no número limite de iterações estabelecido para a estratégia de busca.

O trabalho atendeu aos objetivos da sua proposta, mas as pesquisas com a heurística da Razão-R ainda não estão concluídas. É necessário expandir os testes, aumentando a complexidade e o número de restrições dos problemas testados e melhorando o algoritmo, para diminuir ainda mais o tempo computacional e facilitar a solução de problemas com dimensões maiores que as testadas até agora.

Considerando a potencialidade da heurística, as pesquisas precisam continuar no sentido de reduzir suas limitações, principalmente no que diz respeito a aplicação nas organizações. A heurística considera ainda somente restrições mínimas de produção, e é necessário que se considere um maior número de restrições a saber, restrições máximas de produção, restrições de caixa, ambientais e outras que as organizações necessitem para a viabilização da utilização desse modelo de gestão.

Os outros algoritmos iterativos de melhoria apresentados ao longo do trabalho sugerem também algumas novas abordagens que merecem ser testadas para a Razão-R:

- considerar como potenciais candidatas, dentre as prescrições não-selecionadas, apenas o sub-conjunto das melhores classificadas pela Razão-R em iterações anteriores;
- implementar versões heurísticas dos métodos *Tabu Search*, *Simulated Annealing* e *Algoritmo Genético* com a Razão-R como função de avaliação;
- alterar o critério de retorno ao conjunto das prescrições descartadas, tendo como base o princípio da alteração dos níveis de energia da heurística *Simulated Annealing*;
- comparar o método da Razão-R com as outras heurísticas iterativas de

melhoria para problemas florestais.

Os problemas modelados com a utilização da programação inteira que apresentem uma estrutura matricial semelhante ao problema básico de gestão florestal são passíveis de solução pela heurística da Razão-R. Existem, portanto, problemas semelhantes em outras áreas do conhecimento para os quais a eficiência da heurística da Razão-R precisa ser testada.

Dada a qualidade da heurística da Razão-R como técnica para solução de problemas de planejamento florestal, é possível prever ganhos substanciais, econômicos e de qualidade das soluções, se organizações florestais brasileiras adotarem essa técnica nos seus sistemas de informações gerenciais. Evidências dessa contribuição puderam ser apresentadas neste trabalho.

BIBLIOGRAFIA

- ABRACAVE Anuário estatístico. Belo Horizonte: ABRACAVE, ano.8, n.24, 1998.
- ANDRADE, J.G. **Introdução em administração rural**. Lavras: ESAL/FAEPE, 1995. 53p.
- ARTHAUD, G.J.; PELKKI, M.H. A comparison of dynamic programming and A* in optimal forest stand management. **Forest Science, USA**, v.42, n.4, p. 498-503, out.1996
- BATEMAN, T.S.; SNELL, S.A. **Administração - construindo vantagem competitiva**. São Paulo: Atlas, 1998. 539p.
- BRACELPA - RELATÓRIO ESTATÍSTICO 1997. O setor de celulose e papel. São Paulo: BRACELPA, 1998.
- BRACELPA - CELULOSE & PAPEL. Mercado – Setor espera substituição de importações em 1999. São Paulo: BRACELPA, ano.15, n.64, 1999.
- BUONGIORNO, J.; GILLESS, J.K. **Forest management and economics - a primer in quantitative methods**. New York: Macmillan Publishing Company, 1987. 285p.
- BORGES, J.G.; FALCÃO, A. Programação dinâmica e gestão de povoamentos com estrutura regular e composição pura - aplicação à Mata Nacional de Leiria. **Revista Florestal, Portugal**, 1999. No Prelo.
- CAMPOS Filho, M.P. Os sistemas de informação e as modernas tendências da tecnologia e dos negócios. **Revista de administração de empresas**, São Paulo, v.34, n.6, p.33-45. nov/dez. 1994.
- CHIANG, A.C. **Matemática para economistas**. 2.ed. São Paulo: Edusp e McGraw-Hill, 1982. 684p.
- CHIAVENATO, I. **Teoria geral da administração: abordagens descritivas e explicativas**. 3.ed. São Paulo: McGraw-Hill, 1987. 606p.

- CLUTTER, J.L.; FORTSON, J.C.; PIENAAR, L.V. et al. **Timber Management: a quantitative approach**. New York: John Wiley & Sons, 1983. 333p.
- CORRÊA, H.L.; GIANESI, I.G. **Just in time, MRP II e OPT - um enfoque estratégico**. São Paulo: Atlas, 1993. 186p.
- CORRÊA, H.L.; GIANESI, I.G.; CAON, M. **Planejamento, programação e controle da produção: MRP II / ERP - conceitos, uso e implantação**. São Paulo: Atlas, 1997. 359p.
- DAVIS, L.S.; JOHNSON, K.N. **Forest management**. New York: McGrawHill, 1987. 781p.
- DRUCKER, P.F. **Administrando em tempos de grandes mudanças**. São Paulo: Pioneira, 1995. 227p.
- DYKSTRA, D.P. **Mathematical programming for natural resource management**. New York: McGraw-Hill, 1984. 317p.
- ERIKSSON, L.O. Two methods for solving stand management problems based on a single tree model. **Forest Science, USA**, v.40, n.4, p.732-758, nov. 1994.
- FLORESTAR ESTATÍSTICO. São Paulo: FLORESTAR., v.4, n.12, out.1997. 90p.
- GLOVER, F. Future path for integer programming and links to artificial intelligence. **Computer Operational Research**, Inglaterra, v.13, n.5, p.533-549, 1986.
- GLOVER, F. **Tabu Search fundamentals and uses**. Colorado: University of Colorado, 1995. 85p.
- GONÇALVES, J.E.L. A necessidade de reinventar as empresas. **Revista de administração de empresas**, São Paulo, v.38, n.2, p.6-17, abr/jun. 1998.
- GORINI, A.P.F. Panorama do setor moveleiro no Brasil, com ênfase na competitividade externa a partir do desenvolvimento da cadeia industrial de produtos sólidos de madeira. **BNDES Setorial**, Rio de Janeiro, n.8, p.3-57, set. 1998.

- GREEN, J. Manufacturers meet global market demands with FCS software. **IEE Solutions**, USA, p.26-30, ago. 1996.
- GUIMARÃES, J.M.P.; SETTE, R.de S. **Administração da produção**. Lavras: ESAL/FAEPE, 1995. 53p.
- GUMAER, R. Beyond ERP and MRP II - Optimized Planning and Synchronized Manufacturing. **IEE Solutions**, USA, p.32-35, set. 1996.
- HOGANSON, H.M.; BORGES, J.G. Using Dynamic Programming and Overlapping Subproblems to Address Adjacency in Large Harvest Scheduling Problems. **Forest Science**, USA, v.44, n.4, p.526-538, nov. 1998.
- HOGANSON, H.M.; ROSE, D.W. A simulation approach for optimal timber management scheduling. **Forest Science**, USA, v.30, n.3, p.220-238, 1984.
- IGNIZIO, J.P.; CAVALIER, T.M. **Linear Programming**. Englewood Cliffs: Prentice Hall, 1994. 666p.
- JOHNSON, K.N.; SCHEURMAN, H.L. Techniques for prescribing optimal timber harvest and investment under different objectives - Discussion and Synthesis. **Forest Science Monograph**, USA, n.18, 1977.
- KANGAS, J. Multiple-use planning of forest resources by using then analytic hierarchy process. **Scandinavian journal of forest research**, Finlândia, v.26, n.3, p.169-176, fev. 1992.
- KANGAS, J.; PUKKALA, T. A decision theoretic approach applied to goal programming of forest management. **Silva Fennica**, Finlândia, v.26, n.3, p. 169-176, fev. 1992.
- KOTLER, P. **Administração de Marketing: análise, implementação e controle** 6.ed. São Paulo: Atlas, 1998. 676p.
- LAYDEN, J.E. A Rapidly changing landscape MES , ERP and scheduling. **Manufacturing Systems**. USA, p.10-18, mar. 1996.
- LAROZE, A.J. Linear programming, Tabu Search method for solving forest-level bucking optimization problems. **Forest Science**. USA, v.45, n.1, p. 108-116, fev. 1999.

- LIU, G.; DAVIS, L.S. Iterative resolution of multi-objective forest planning problems with shadow price and parametric analysis. **Forest Science, USA**, v.41, n.3, p.452-469, 1995.
- LEUSCHNER, W.A **Introduction to forest resource management**. New York: John Wiley & Sons, 1984. 277p.
- MACEDO, A.R.P.; ROQUE, C.A.L. Painéis de Madeira. **BNDES Setorial**, Rio de Janeiro, n.6, p.117-132, set. 1997.
- MACEDO, A.R.P.; VALENÇA, A.C.V. O terceiro ciclo de investimentos da indústria brasileira de papel e celulose. **BNDES Setorial**, Rio de Janeiro, n. 4, p.113-121, set. 1996.
- MACEDO, A.R.P.; LEITE, E.T.L. Papel de imprensa. **BNDES Setorial**, Rio de Janeiro, n.7, p.110-121, mar. 1998.
- MORTON, T.E.; PENTICO, D.W. **Heuristic scheduling systems**. New York: Wiley, 1996. 695p.
- MOREIRA, D.A. **Administração da produção e operações**. 2.ed. São Paulo: Pioneira, 1996. 618p.
- MURRAY, A.T.; CHURCH, R.L. Heuristic Solution Approaches Forest Planning Problems. **OR Spektrum, USA**, v.17, p.193-203, 1995.
- MURRAY, A.T.; CHURCH, R.L. Analyzing Cliques for imposing adjacency restrictions in forest models. **Forest Science, USA**, v.42, n.2, p.45-52, 1996.
- MURRAY, A.T. Spatial Restrictions in Harvest Scheduling **Forest Science, USA**, v.45, n.1, p.45-52, fev. 1999.
- NILSSON, N. **Principles of artificial intelligence**. New York: Springer-Verlag, 1982. 476p.
- OLIVEIRA, D.P.R **Sistemas de Informações Gerenciais**. 2.ed. São Paulo, Atlas: 1993. 267p.

- PAIVINEN, R. Large-scale forestry scenario models – where are we? In: INTERNATIONAL SEMINAR LARGE-SCALE FORESTRY SCENARIO MODELS: EXPERIENCES AND REQUIREMENTS, 1995, Joensuu-Finlândia. **Proceedings...** Joensuu-Finlândia: European Forest Institute, 1996, n.5, p.5-14.
- REZENDE, J.L.P.; OLIVEIRA, A D.de. **Avaliação de Projetos 1 e 2** . Lavras: ESAL-FAEPE, 1995. 65p. Apostila.
- RICH, E.; KNIGHT,K. **Inteligência Artificial**. 2.ed. São Paulo: Makron Books, 1993. 243p.
- RODRIGUEZ, L.C.E.; LIMA, A.B.N.P.M. A utilização da programação linear na determinação de uma estratégia ótima de reforma de um talhão florestal. **IPEF**, Piracicaba, n.31, p.47-53, 1985.
- RODRIGUEZ, L.C.E.; LIMA, A.B.N.P.M.de; BUENO, A.C. et al. Programação linear no planejamento florestal: uma aplicação prática. In: CONGRESSO FLORESTAL BRASILEIRO, 5., 1986, Olinda. **Anais...** São Paulo: SBS, 1986. *Silvicultura*, v.41, n.11, p.163-168.
- RODRIGUEZ, L.C.E.; MOREIRA, R.M. Gerenciamento de florestas de eucalipto com modelos de programação linear. **IPEF Série Técnica**, Piracicaba, n.6, p.1-15, 1989.
- RODRIGUEZ, L.C.E. Gerenciamento da Produção Florestal. **Documentos Florestais - DCF**, Piracicaba, n.13, p.1-41, 1991.
- RODRIGUEZ, L.C.E. **Use of heuristic methods in the analysis of large-scale forest management integer programming models**. Athens-Georgia: University of Georgia, 1994. 93p. (Tese de doutorado)
- RODRIGUEZ, L.C.E. A microcomputer program for solving forest scheduling problems with heuristic approaches. In: INTERNATIONAL SEMINAR LARGE-SCALE FORESTRY SCENARIO MODELS: EXPERIENCES AND REQUIREMENTS, 1995, Joensuu-Finlândia. **Proceedings...** Joensuu-Finlândia: European Forest Institute, 1996, n.5,p.153-163.
- RODRIGUEZ, L.C.E.; BATISTA, J.L.F.; COUTO, H.T.Z. **Matemática Financeira na Gestão Florestal**. Piracicaba: Departamento de Ciências Florestais da ESALQ/USP, 1996. 38 p.(a)

- RODRIGUEZ, L.C.E.; BATISTA, J.L.F.; COUTO, H.T.Z. **Técnicas e modelos quantitativos de suporte à decisão florestal - Programa de reciclagem em métodos quantitativos.** Piracicaba: ESALQ-USP-IPEF, 1996. 21p. Apostila.(b)
- RODRIGUEZ, L.C.E.; MCTAGUE, J.P. Integer solution for model I harvest scheduling LP problems: testing the R-Ratio heuristic. In: SYMPOSIUM ON SYSTEMS ANALYSIS IN FOREST RESOURCES, 7., 1997. Bellaire, 1997. **Proceedings...** No prelo.
- RODRIGUEZ, L.C.E. **Técnicas quantitativas para gestão de florestas plantadas.** Piracicaba: ESALQ-USP, 1999. 120p. (Tese de Livre-Docência)
- ROQUE, C.A.L.; VALENÇA, A.C.V. Painéis de madeira aglomerada. **BNDES Setorial**, Rio de Janeiro, n.8, p.153-170, set. 1998.
- RUSSEL, S.J.; NORVIG, P. **Artificial Intelligence: a modern approach.** New Jersey: Prentice Hall, 1995. 929 p.
- SALEGNA, G. Integrating the planning and scheduling systems in a job shop. **Production and Inventory Management Journal.** USA, v.37, n.4, p.1-6, out/dez 1996.
- SCOLFORO, J.R.S. **Sistema integrado para predição e análise presente e futura do crescimento e produção, com otimização de capitais, para *Pinus caribaea* var. *hondurensis*.** Curitiba: Universidade Federal do Paraná, 1990. 287p. (Tese de doutorado em ciências florestais)
- SCOLFORO, J.R.S. **Manejo florestal.** Lavras: UFLA-FAEPE, 1997. 438p.
- SILVA, M. Que é Interatividade. **Boletim Técnico do SENAC.** Rio de Janeiro, v.24, n.2, p.27-35, mai/ago 1998.
- SILVA Jr, A.G. **Sistema de suporte a decisão integrado a sistemas especialistas: uma aplicação para gerenciamento de fazendas produtoras de leite.** Viçosa, UFV, 1993. 94p. (Tese de mestrado)
- SNYDER, R.L.; ReVELLE, C. The grid packing problem: selecting a harvesting pattern in an area with forbidden regions. **Forest Science.** USA, v.42, n.1, p.27-34, 1996.

- SONG, T. Decision support in selection cutting planning of uneven-aged stand management. Finlândia: Severiges Lantbruksuniversitet, Instituto de economia, Arbetsrapport 170, 1993. 25p.
- TE LHADA, M.A.L. Resolução de um modelo de programação linear para planejamento florestal. Campinas: UNICAMP, 1986. 232p. (Tese de mestrado em matemática aplicada)
- WALTERS, D.K. EK, A.R. Whole stand yield and density equations for fourteen forest types in Minnesota. Northern Journal of Applied Forestry, USA, v.10, n.20, p.75-85. 1993.
- WEINTRAUB, A ; BARAHONA, F. ; EPSTEIN, R. A column generation algorithm for solving general forest planning problems with adjacency constraints. Forest Science, v.40, n.1, p.142-161. Fev. 1994.
- WEINTRAUB, A Planning packages: will the computer do it all? In: Harvest planning Nova Zelândia: Logging industry research organization, Proceedings , 1995, p.1-7.
- WEINTRAUB, A; JONES, G.; MEACHAM, M. et al. Heuristic procedures for solving mixed-integer harvest scheduling - transportation planning models. Canadian journal forest research. Canada, v.25, p.1618-1626, abr. 1995.
- YOSHIMOTO, A.; BRODIE, J.D. Comparative analysis of algorithms to generate adjacency constraints. Canadian journal forest research. Canada, v.24, n.6. p.1277-1288. Jun.1994.(a)
- YOSHIMOTO, A.; BRODIE, J.D. Short and long-term impacts of spatial restrictions on harvest scheduling with reference to riparian zone planning. Canadian journal forest research. Canada, v.24, n.8. p.1617-1629, ago. 1994.(b)

ANEXOS

ANEXO A – Gráficos com os resultados dos testes

	Página
TABELA 1A – Resultados de todos os testes de avaliação	098
GRÁFICO 1A – Alfa e Beta das Melhores Soluções	106
GRÁFICO 2A – Estratégias sem solução	106
GRÁFICO 3A – Resultados do problema EUCA1	107
GRÁFICO 4A – Resultados do problema EUCA2	108
GRÁFICO 5A – Resultados do problema EUCA3	109
GRÁFICO 6A – Resultados do problema EUCA4	110
GRÁFICO 7A – Resultados do problema MODELO1	111
GRÁFICO 8A – Resultados do problema MODELO2	112
GRÁFICO 9A – Resultados do problema MODELO3	113
GRÁFICO 10A – Resultados do problema MODELO4	114
GRÁFICO 11A – Resultados do problema APACHE1	115

GRÁFICO 12A -	Resultados do problema APACHE2	116
GRÁFICO 13A -	Resultados do problema APACHE3	117
GRÁFICO 14A -	Resultados do problema MINESOTA1	118
GRÁFICO 15A -	Resultados do problema MINESOTA2	119
GRÁFICO 16A -	Resultados do problema MINESOTA3	120

TABELA 1A – Resultados de todos os testes de avaliação

Problema >>	Euca1	Euca2	Euca3	Euca4
Número de variáveis	100	155	100	155
Número de unidades	20	30	20	30
Número de períodos	21	21	21	21
Restrição de produção anual	5000	8000	5000	8000
Coefficientes	VPL	VPL*	Volume	VPL
TPV max sem restrições	217.372,00	298.000,20	64.301,94	297.930,00
TPV ótimo contínuo	207.450,11	280.392,34	62.844,43	280.508,50
TPV ótimo inteiro	204.329,70	278.577,90	62.587,98	278.439,40
Melhor Solução RR	204.129,70	278.172,20	62.392,35	277.993,10
% máximo sem restrições	93,91%	93,35%	97,03%	93,31%
% ótimo contínuo	98,40%	99,21%	99,28%	99,10%
% ótimo inteiro	99,90%	99,85%	99,69%	99,84%
Alfa	22	27	13	30
Beta	2	2	7	2
Iterações	50	90	53	99
Tempo (segundos)	0	0	0	0
Mais vezes				
Solução de menor custo	201.607,80	274.720,30	62.097,74	274.704,30
Alfa	29	32	9	36
Beta	3	11	17	4
Iterações	41	66	42	59
% da Melhor Solução	98,76%	98,76%	99,53%	98,82%
Solução de maior custo	198.761,70	277.075,60	61.982,08	277.598,50
Alfa	20	13	27	14
Beta	3	2	2	2
Iterações	101	156	101	183
% da Melhor Solução	97,37%	99,61%	99,34%	99,86%
Pior Solução	194.509,00	270.052,00	61.203,45	264.761,40
Alfa	30	27	14	16
Beta	12	10	15	4
Iterações	56	89	83	151
% da Melhor Solução	95,29%	97,08%	98,09%	95,24%

TABELA 1A - Resultados de todos os testes de avaliação – Continuação

	Euca1	Euca2	Euca3	Euca4
Nr de estratégias calculadas	744	757	744	741
estratégias sem solução	177	357	361	321
est. sem sol. beta > 10	23,8%	47,2%	48,5%	43,3%
est. sem sol. beta > 100	113	232	296	224
est. sem sol. alfa > 10	0	0	0	0
est. sem sol. alfa > 100	123	232	300	232
est. sem sol. alfa > 100	0	0	0	0
Resultados em % /sem solução				
beta > 10	63,8%	65,0%	82,0%	69,8%
alfa > 10	69,5%	65,0%	83,1%	72,3%
Cálculo da Penetrance				
Iterações da melhor solução	50	90	53	99
Iterações sobre os não selec.	35	58	46	64
Nós expandidos	2188	5534	2632	5921
Penetrance	0,022857	0,016262	0,020139	0,016719
Complexidade				
alfa da sol. maior custo	20	13	27	14
beta da sol. de maior custo	3	11	17	4
nós expandidos efetivos	8080	19500	8080	22875
Complexidade	10213	21114	8424	23906
sol maior custo / complexidade	79%	92%	96%	96%

TABELA 1A - Resultados de todos os testes de avaliação – Continuação

Problema >>	Modelo1	Modelo2	Modelo3	Modelo4
Número de variáveis	288	288	288	288
Número de unidades	32	32	32	32
Número de períodos	21	21	21	21
Restrição de produção anual	18000	19000	18000	19000
Coefficientes	VPL*	VPL*	VPL	VPL
TPV max sem restrições	3.209.295,13	3.209.295,13	3.588.282,89	3.588.282,89
TPV ótimo contínuo	3.199.613,22	3.197.347,79	3.576.333,68	3.578.599,27
TPV ótimo inteiro	3.197.662,04	3.195.284,10	3.573.442,50	3.576.446,43
Melhor Solução RR	3.195.893,85	3.194.170,59	3.573.156,07	3.574.879,38
% máximo sem restrições	99,58%	99,53%	99,58%	99,63%
% ótimo contínuo	99,88%	99,90%	99,91%	99,90%
% ótimo inteiro	99,94%	99,97%	99,99%	99,96%
Alfa	16	25	25	16
Beta	5	6	6	5
Iterações	102	85	85	102
Tempo (segundos)	1	1	0	0
Mais vezes				
Solução de menor custo	3.193.279,50	3.194.170,29	3.573.155,78	3.572.264,84
Alfa	11	24	24	11
Beta	10	8	8	10
Iterações	83	83	83	83
% da Melhor Solução	99,92%	100,00%	100,00%	99,93%
Solução de maior custo	3.165.648,67	3.158.789,50	3.537.776,01	3.544.635,49
Alfa	21	14	14	21
Beta	10	8	8	10
Iterações	245	251	251	245
% da Melhor Solução	99,05%	98,89%	99,01%	99,15%
Pior Solução	3.156.907,25	3.147.472,11	3.526.457,63	3.535.894,08
Alfa	28	16	16	28
Beta	17	19	19	17
Iterações	234	216	216	234
% da Melhor Solução	98,78%	98,54%	98,69%	98,91%

TABELA 1A - Resultados de todos os testes de avaliação – Continuação

Problema >>	Modelo1	Modelo2	Modelo3	Modelo4
Nr de estratégias calculadas	813	801	631	632
estratégias sem solução	67	141	110	26
	8,2%	17,6%	17,4%	4,1%
est. sem sol. beta > 10	22	103	99	24
est. sem sol. beta > 100	0	0	0	0
est. sem sol. alfa > 10	40	102	91	22
est. sem sol. alfa > 100	0	0	0	0
Resultados em % /sem solução				
beta > 10	32,8%	73,0%	90,0%	92,3%
alfa > 10	59,7%	72,3%	82,7%	84,6%
Cálculo da Penetrance				
Iterações da melhor solução	102	85	85	102
Iterações sobre os não selec.	84	74	74	84
Nós expandidos	17942	16206	16206	17942
Penetrance	0,005685	0,005245	0,005245	0,005685
Complexidade				
alfa da sol. maior custo	21	14	14	21
beta da sol. de maior custo	10	8	8	10
nós expandidos efetivos	62720	64256	64256	62720
Complexidade	80819	82752	82752	80819
sol maior custo / complexidade	78%	78%	78%	78%

TABELA 1A - Resultados de todos os testes de avaliação – Continuação

Problema >>	Apache1	Apache2	Apache3
Número de variáveis	2584	2584	2584
Número de unidades	152	152	152
Número de períodos	15	15	15
Restrição de produção anual	10000000	12000000	10000000
Coefficientes	VPL	VPL	VPL*
TPV max sem restrições	275.057.822,00	275.057.822,00	240.881.248,00
TPV ótimo contínuo	248.999.599,80	253.164.365,54	219.810.923,75
TPV ótimo inteiro			
Melhor Solução RR	247.469.360,00	252.426.384,00	216.447.930,00
% máximo sem restrições	89,97%	91,77%	89,86%
% ótimo contínuo	99,39%	99,71%	98,47%
% ótimo inteiro			
Alfa	9	9	20
Beta	3	3	3
Iterações	1137	918	1222
Tempo (segundos)	84	76	85
Mais vezes			
Solução de menor custo	246.584.131,00	252.238.094,00	215.523.547,00
Alfa	13	10	75
Beta	2	3	2
Iterações	1008	887	885
% da Melhor Solução	99,64%	99,93%	99,57%
Solução de maior custo	236.910.924,00	242.475.988,00	208.000.404,00
Alfa	360	75	200
Beta	220	70	102
Iterações	2456	2564	2534
% da Melhor Solução	95,73%	96,06%	96,10%
Pior Solução	223.914.125,00	240.899.247,00	203.055.459,00
Alfa	250	20	140
Beta	85	80	152
Iterações	2001	1642	1893
% da Melhor Solução	90,48%	95,43%	93,81%

TABELA 1A - Resultados de todos os testes de avaliação – Continuação

Problema >>	Apache1	Apache2	Apache3
Nr de estratégias calculadas	1607	1001	896
estratégias sem solução	260	74	149
	16,2%	7,4%	16,6%
est. sem sol. beta > 10	260	74	149
est. sem sol. beta > 100	223	0	143
est. sem sol. alfa > 10	258	69	145
est. sem sol. alfa > 100	248	0	105
Resultados em % /sem solução			
beta > 10	100,0%	100,0%	100,0%
alfa > 10	99,2%	93,2%	97,3%
Cálculo da Penetrance			
Iterações da melhor solução	1137	918	1222
Iterações sobre os não selec.	760	614	820
Nós expandidos	1559520	1304750	1658577
Penetrance	0,000729	0,000704	0,000737
Complexidade			
alfa da sol. maior custo	360	75	200
beta da sol. de maior custo	2	3	2
nós expandidos efetivos	5972992	6235648	6162688
Complexidade	8991104	8320683	9185664
sol maior custo / complexidade	66%	75%	67%

TABELA 1A - Resultados de todos os testes de avaliação – Continuação

Problema >>	Minesota1	Minesota2	Minesota3
Número de variáveis	605	17620	17620
Número de unidades	70	2102	2102
Número de períodos	15	15	15
Restrição de produção anual	4000000	115000000	121000000
Coefficientes	VPL	VPL	VPL
TPV max sem restrições	95.058.613,00	3.569.538.192,00	3.569.538.192,00
TPV ótimo contínuo	90.216.190,94	3.496.948.750,45	3.491.891.500,45
TPV ótimo inteiro			
Melhor Solução RR	89.860.574,00	3.491.462.320,00	3.482.495.031,00
% máximo sem restrições	94,53%	97,81%	97,56%
% ótimo contínuo	99,61%	99,84%	99,73%
% ótimo inteiro			
Alfa	9	190	70
Beta	3	6	5
Iterações	169	3680	4204
Tempo (segundos)	3	1173	2356
Mais vezes	3		5
Solução de menor custo	89.807.094,00	3.489.863.988,00	3.478.304.230,00
Alfa	43	100	70
Beta	26	8	8
Iterações	143	3599	3853
% da Melhor Solução	99,94%	99,95%	99,88%
Solução de maior custo	86.196.456,00	3.475.946.444,00	3.434.716.854,00
Alfa	10	10	20
Beta	210	210	90
Iterações	335	5001	5001
% da Melhor Solução	95,92%	99,56%	98,63%
Pior Solução	80.990.604,00	3.466.263.997,00	3.434.716.854,00
Alfa	20	10	20
Beta	139	130	90
Iterações	301	4201	5001
% da Melhor Solução	90,13%	99,28%	98,63%

TABELA 1A - Resultados de todos os testes de avaliação – Continuação

Problema >>	Minesota1	Minesota2	Minesota3
Nr de estratégias calculadas	6878	304	252
estratégias sem solução	576	35	88
	8,4%	11,5%	34,9%
est. sem sol. beta > 10	459	26	61
est. sem sol. beta > 100	436	22	0
est. sem sol. alfa > 10	540	21	53
est. sem sol. alfa > 100	90	19	0
Resultados em % /sem solução			
beta > 10	79,7%	74,3%	69,3%
alfa > 10	93,8%	60,0%	60,2%
Cálculo da Penetrance			
Iterações da melhor solução	169	3680	4204
Iterações sobre os não selec.	115	3097	3376
Nós expandidos	54772	43267682	46692508
Penetrance	0,003085	0,000085	0,000090
Complexidade			
alfa da sol. maior custo	10	10	20
beta da sol. de maior custo	26	8	8
nós expandidos efetivos	179225	77605518	77605518
Complexidade	336453	307601676	307582278
sol maior custo / complexidade	53%	25%	25%

GRÁFICO 1A – Alfa e Beta das Melhores Soluções

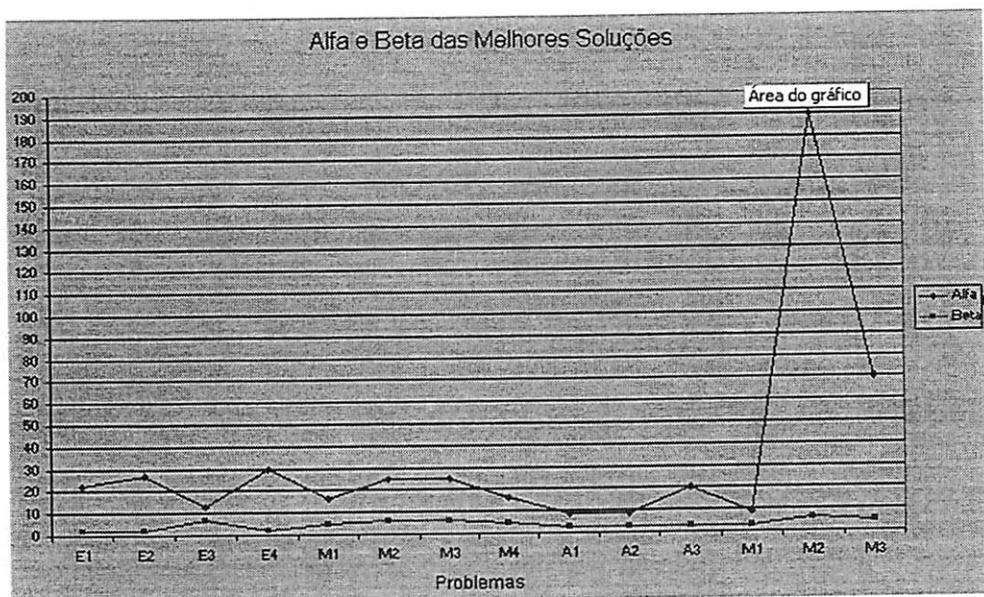


GRÁFICO 2A – Estratégias sem solução

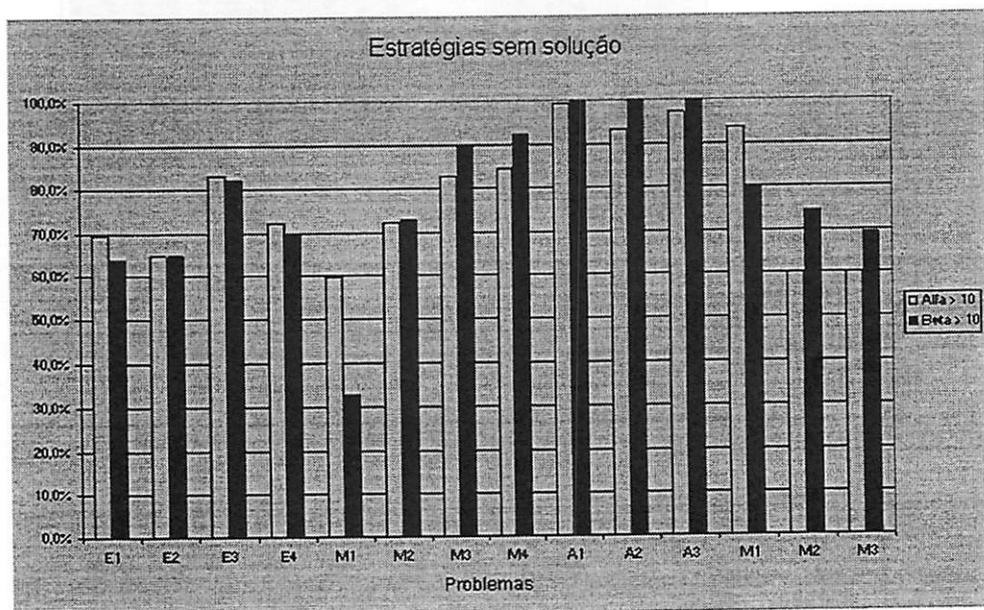


GRÁFICO 3A - Resultados do problema EUCA1

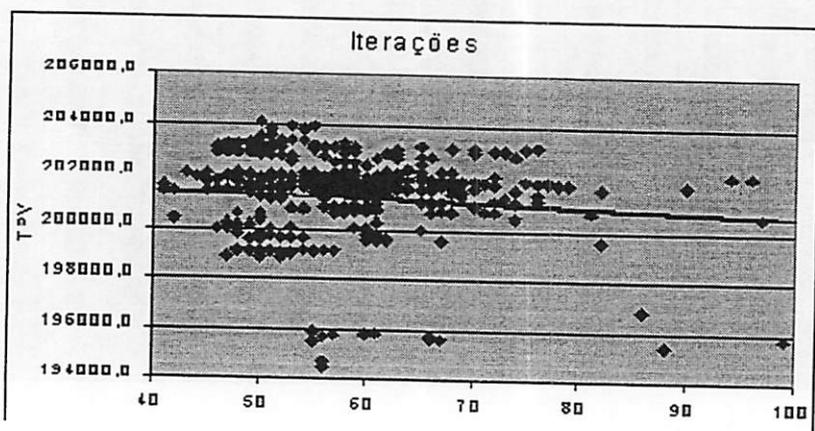
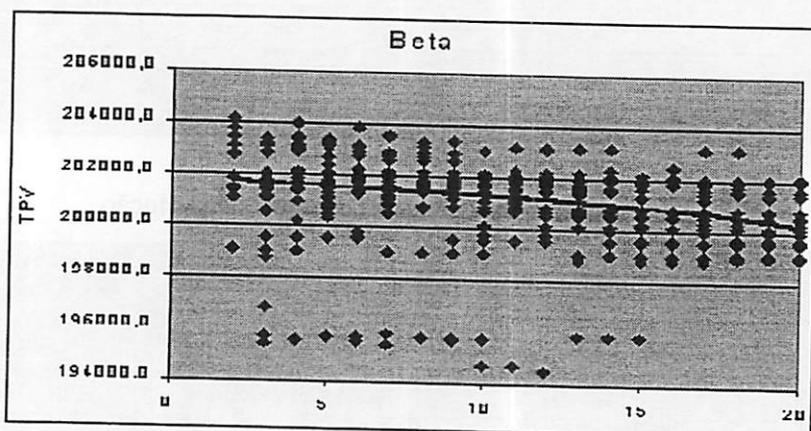
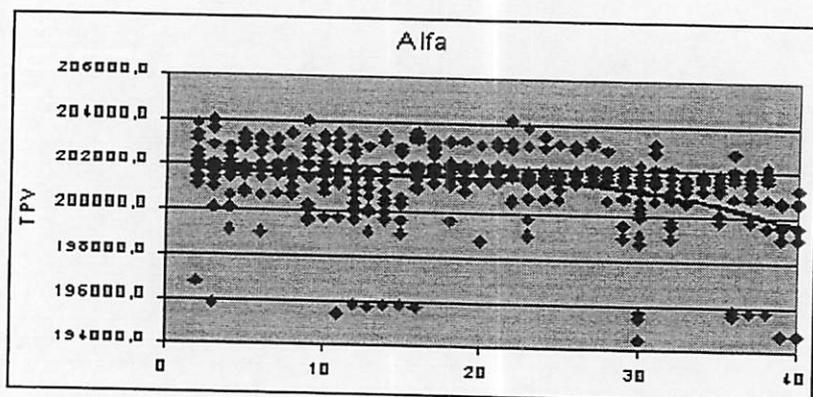


GRÁFICO 4A - Resultados do problema EUCA2

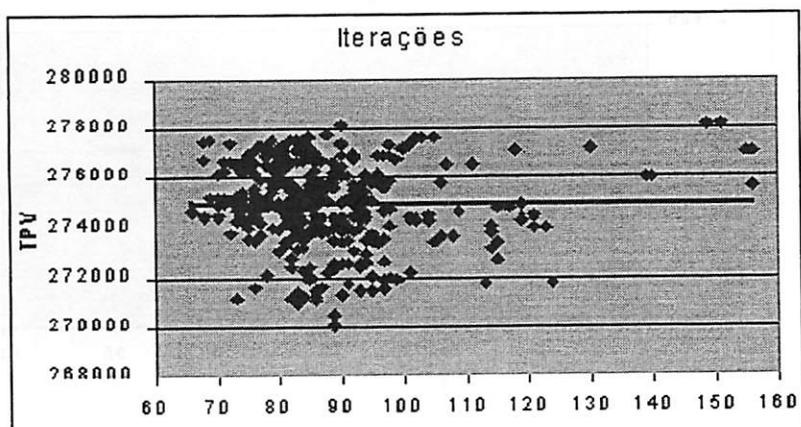
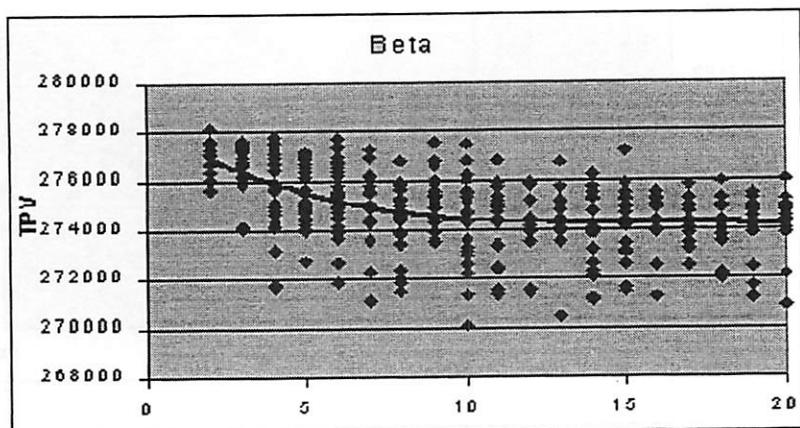
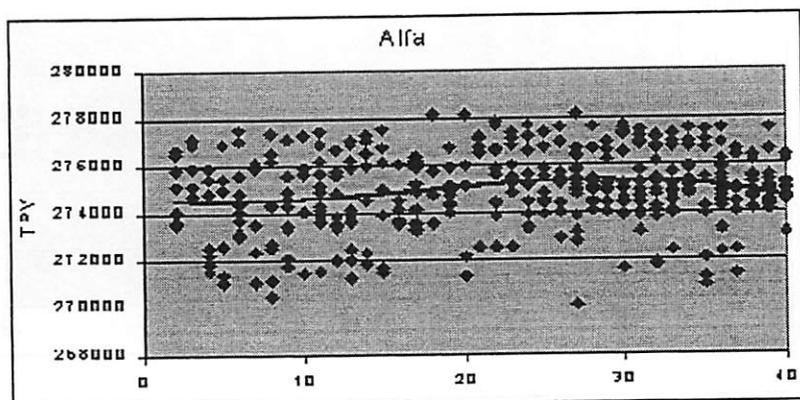


GRÁFICO 5A - Resultados do problema EUCA3

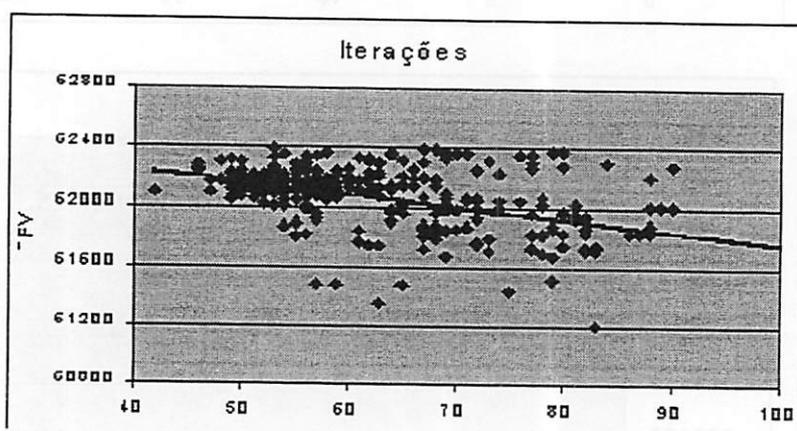
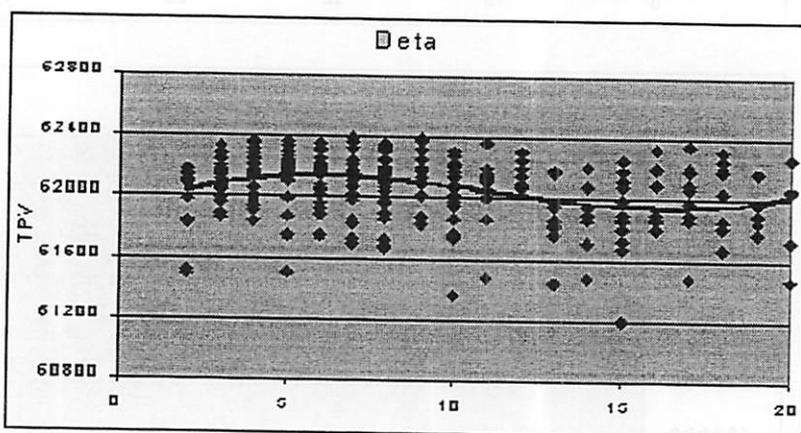
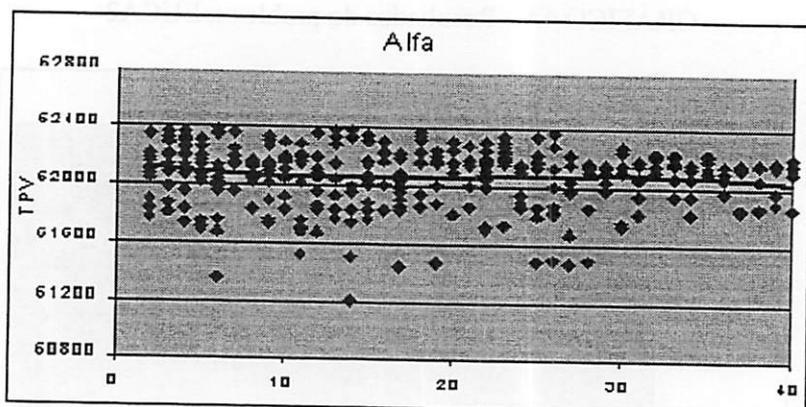


GRÁFICO 6A - Resultados do problema EUCA4

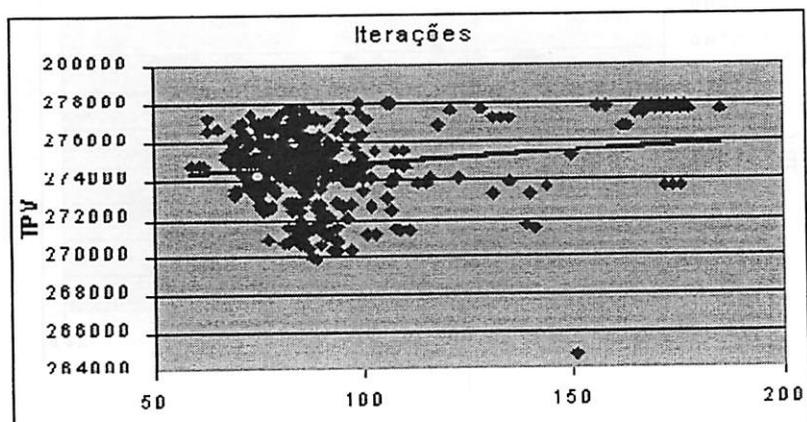
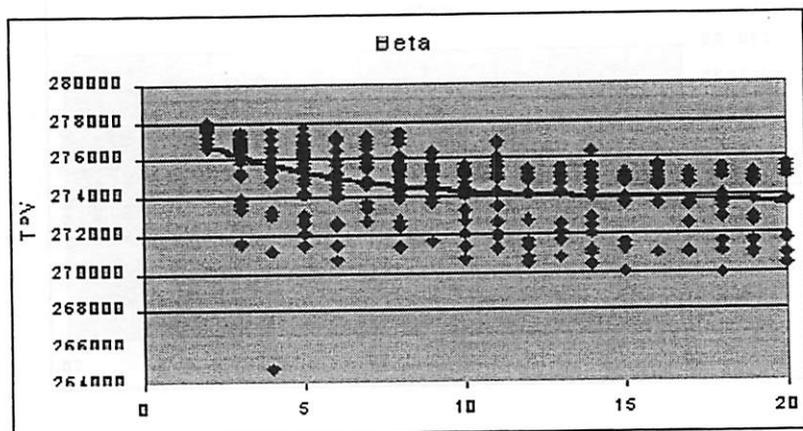
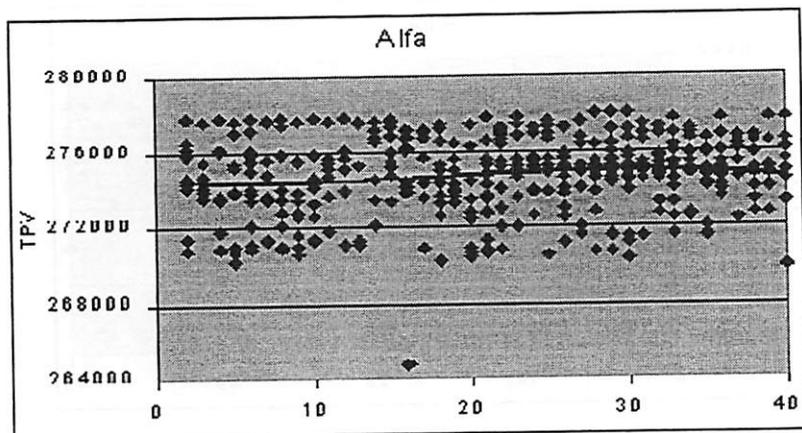


GRÁFICO 7A - Resultados do problema MODELO1

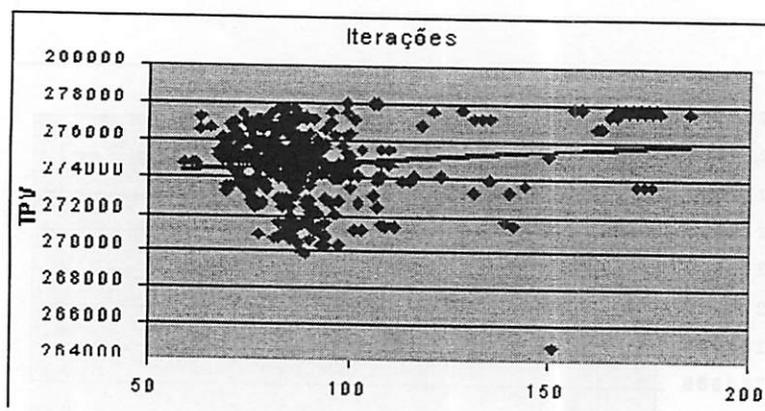
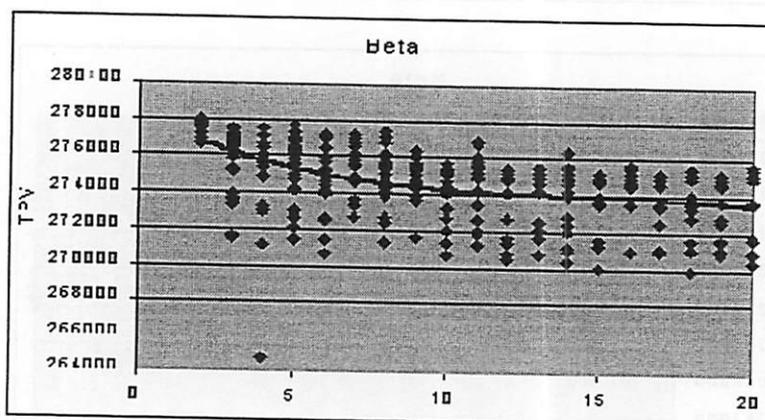
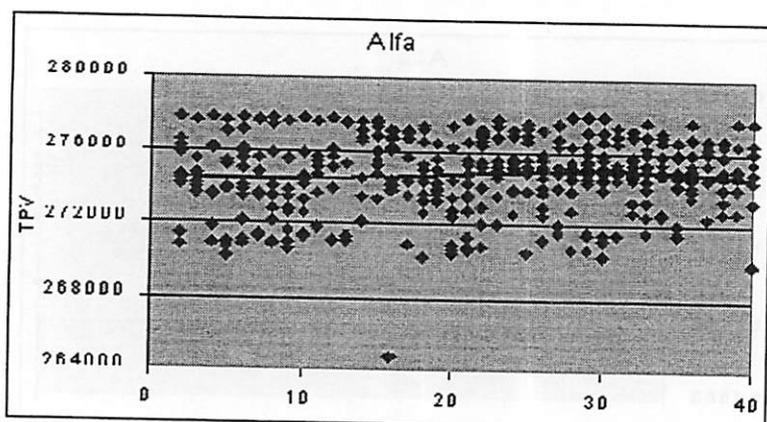


GRÁFICO 8A - Resultados do problema MODELO2

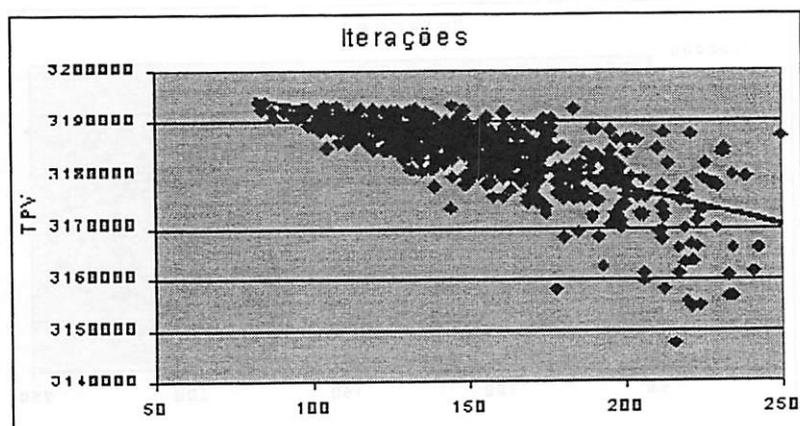
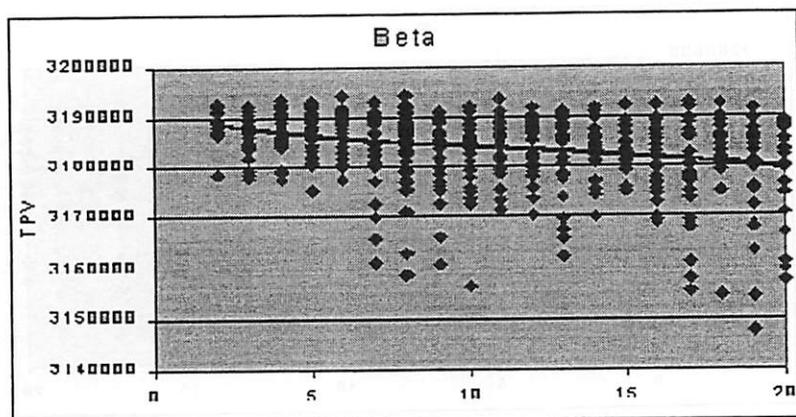
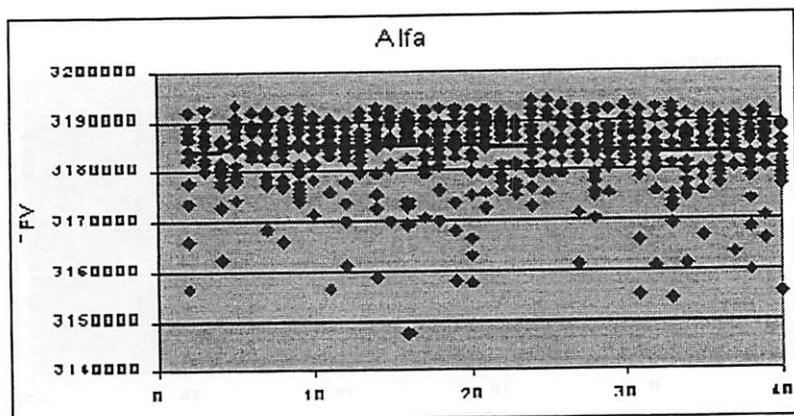


GRÁFICO 9A - Resultados do problema MODELO3

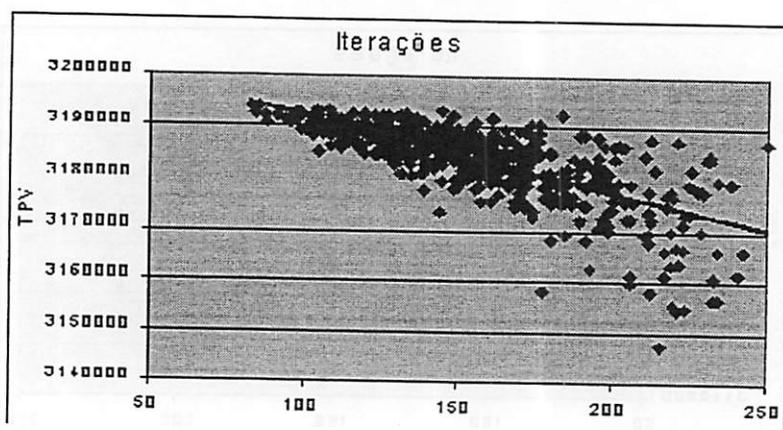
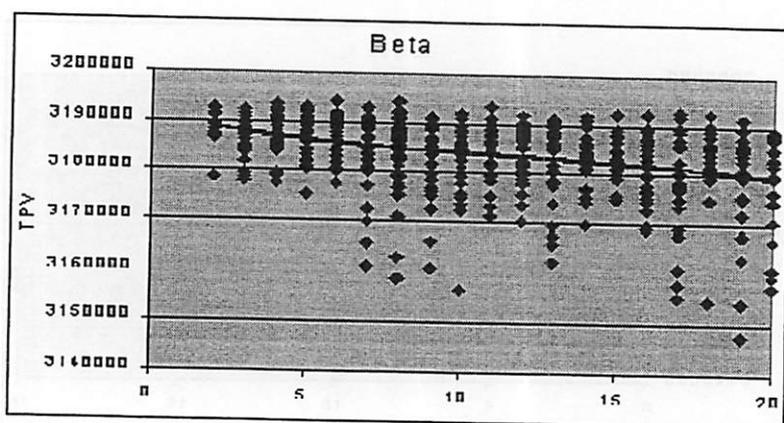
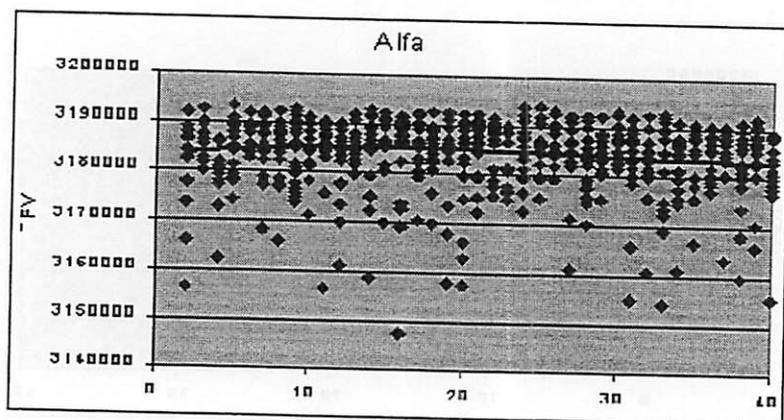


GRÁFICO 10A - Resultados do problema MODELO4

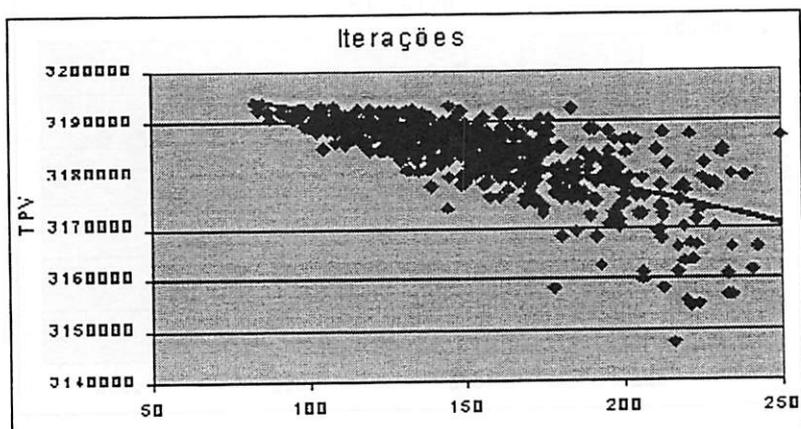
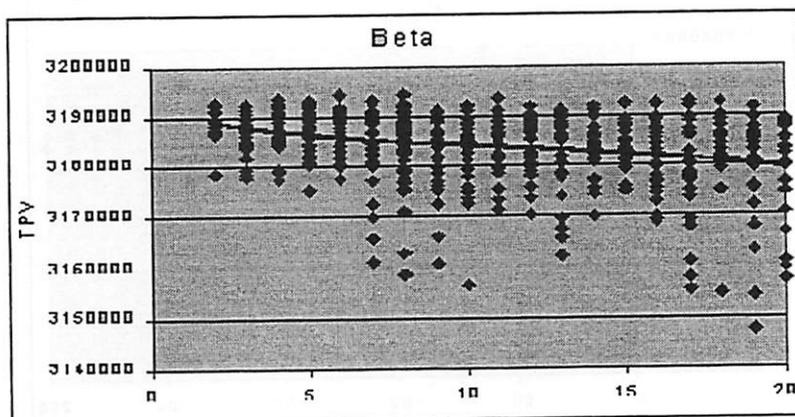
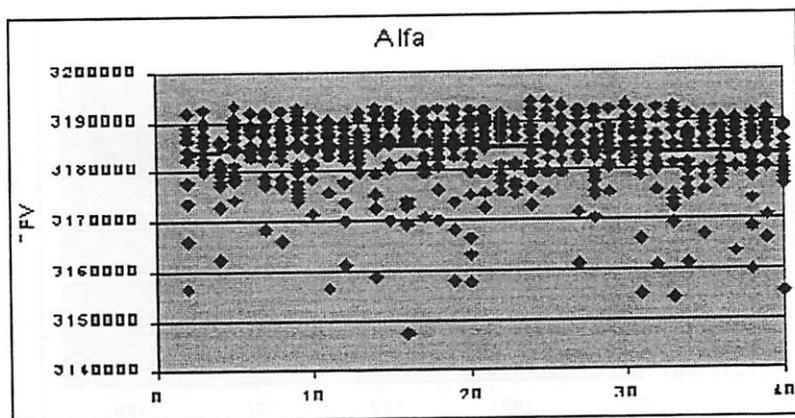


GRÁFICO 11A - Resultados do problema APACHE1

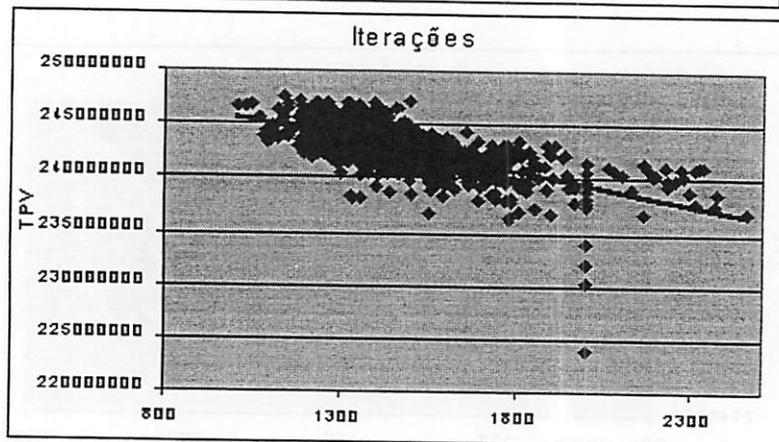
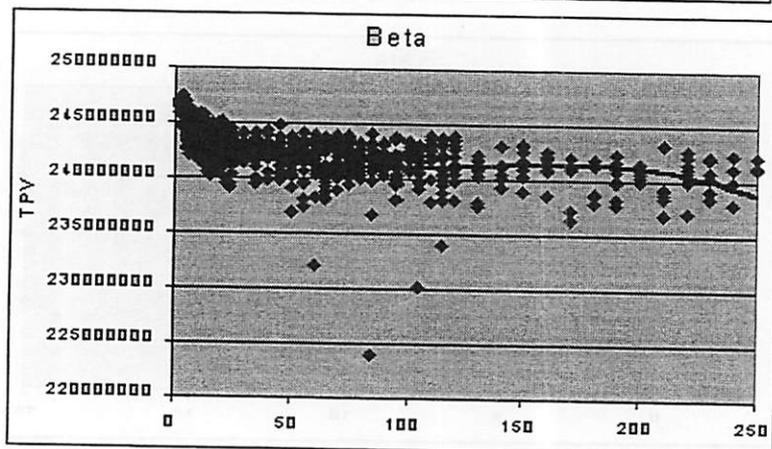
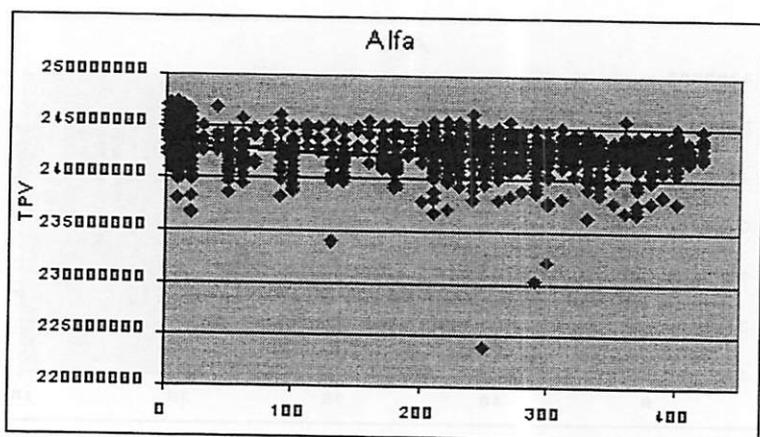


GRÁFICO 12A - Resultados do problema APACHE2

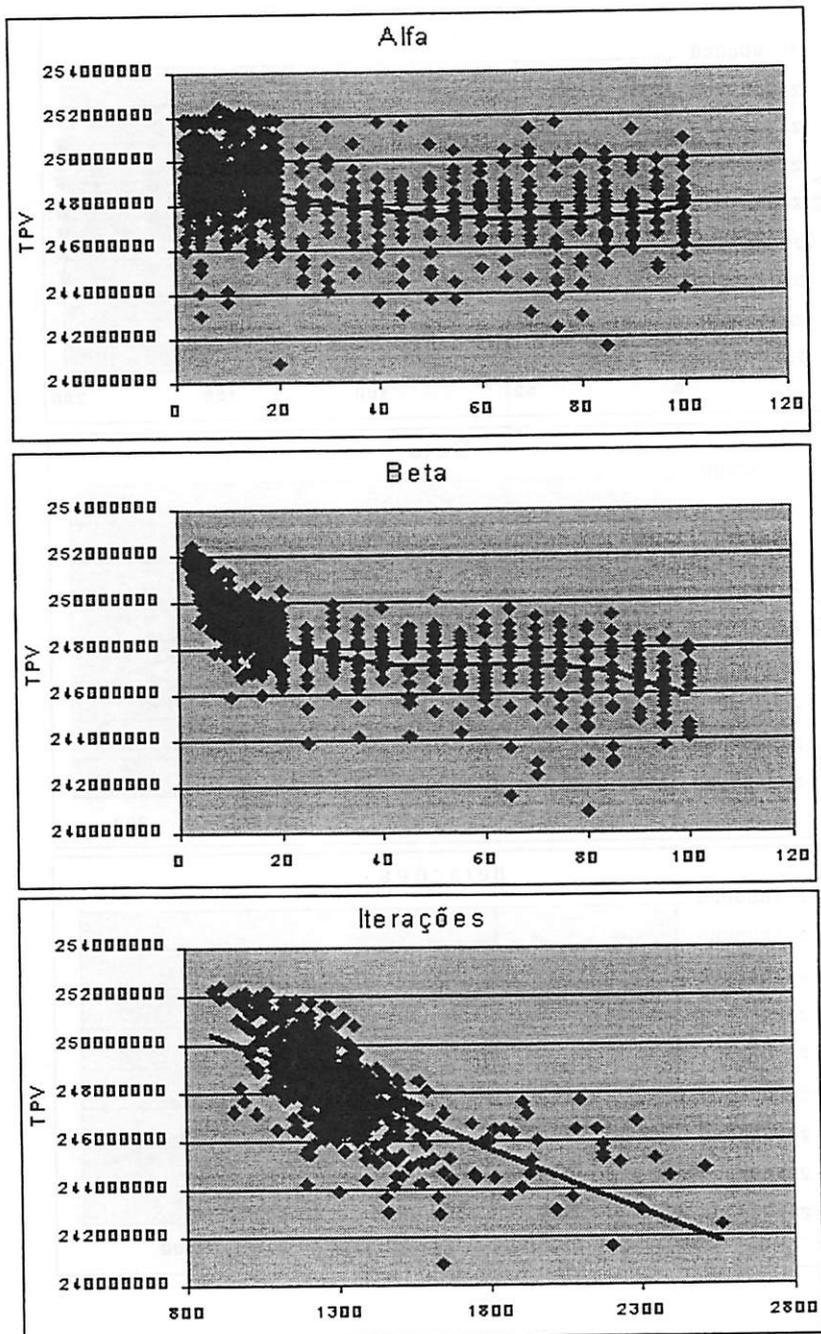


GRÁFICO 13A - Resultados do problema APACHE3

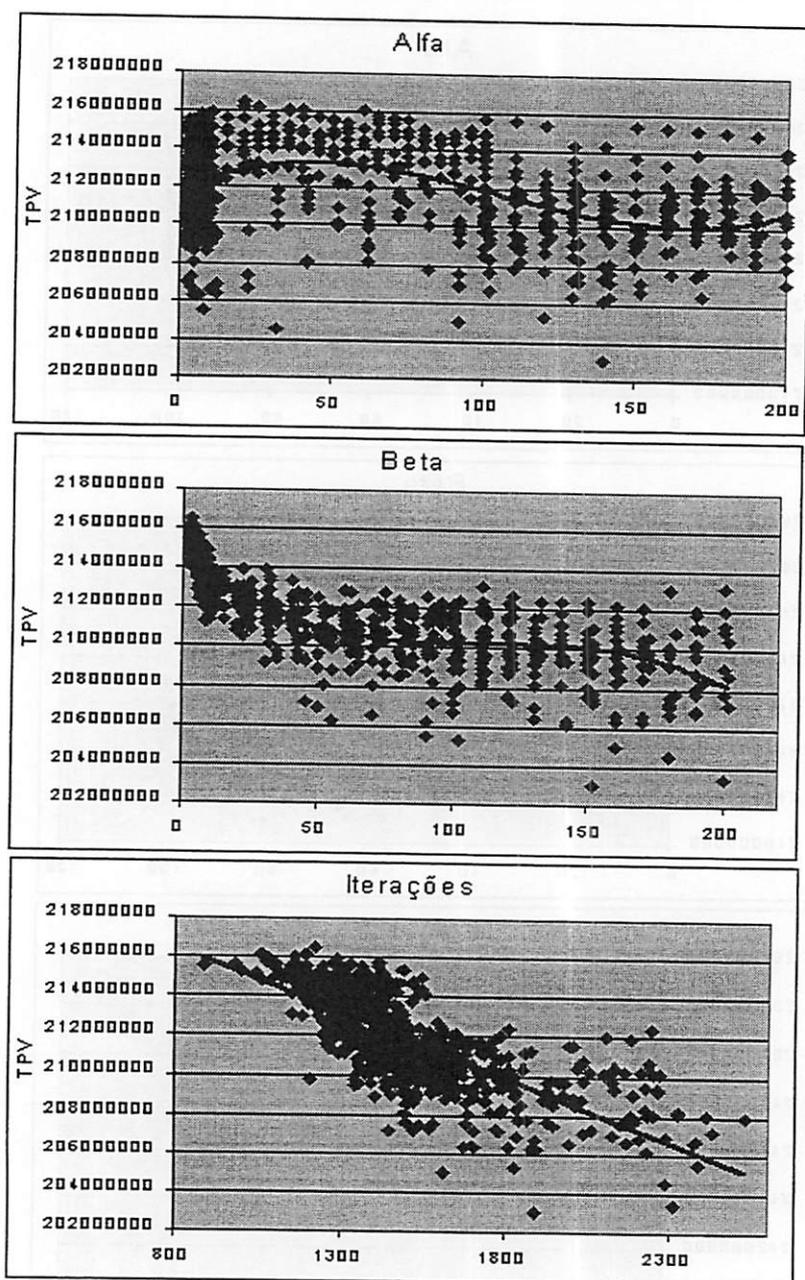


GRÁFICO 14A - Resultados do problema MINESOTA1

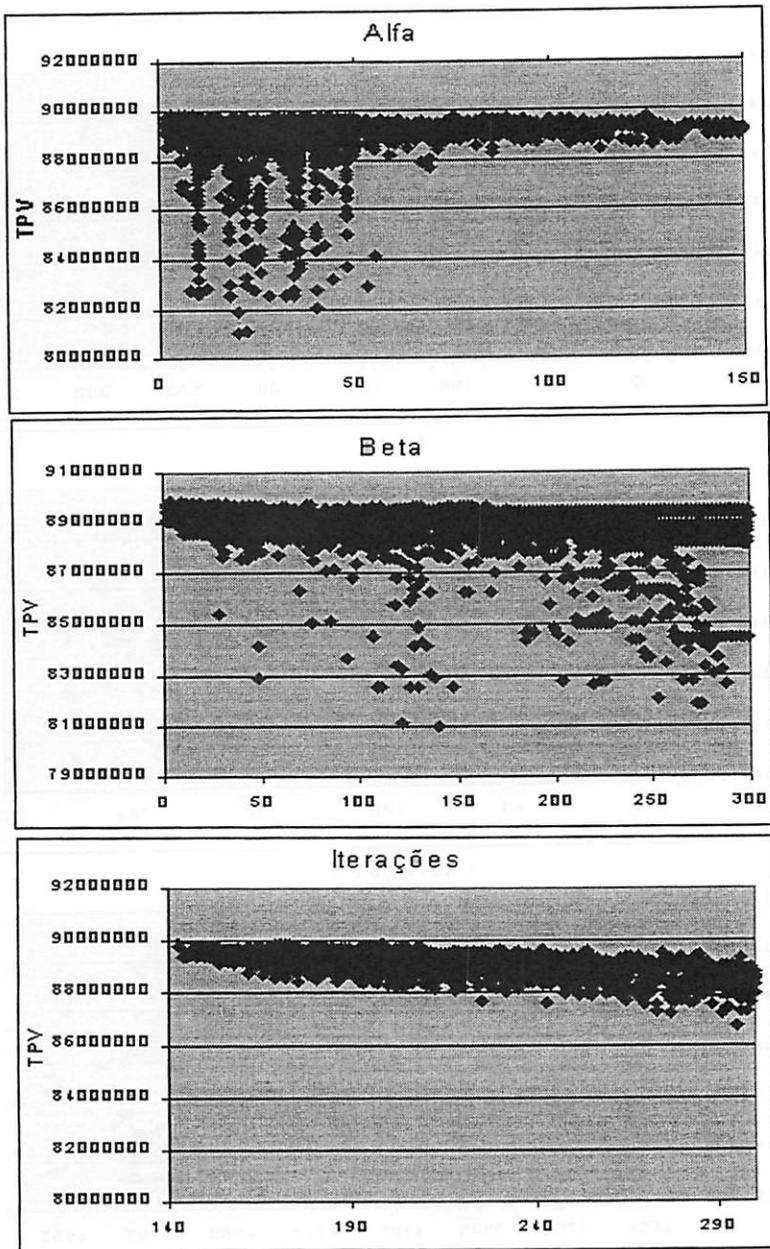


GRÁFICO 15A - Resultados do problema MINESOTA2

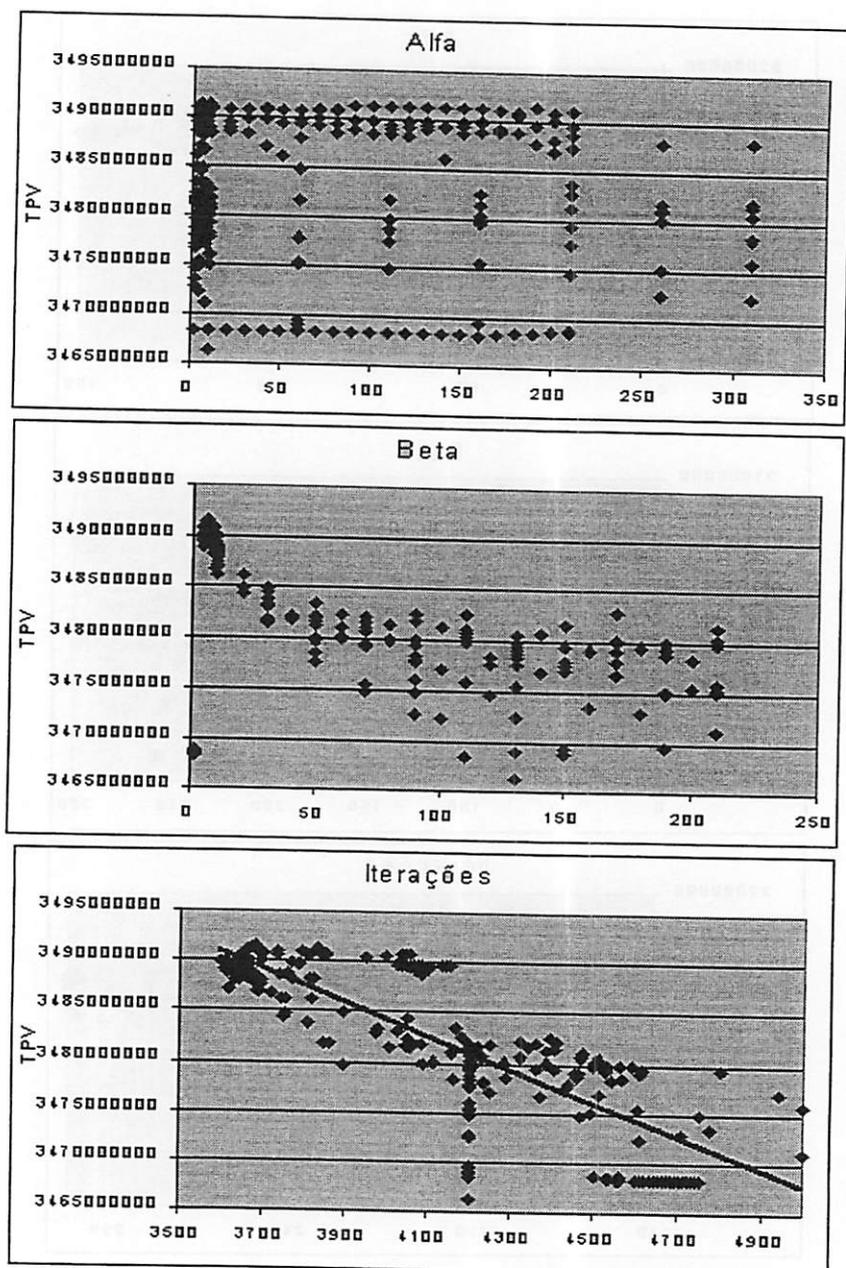
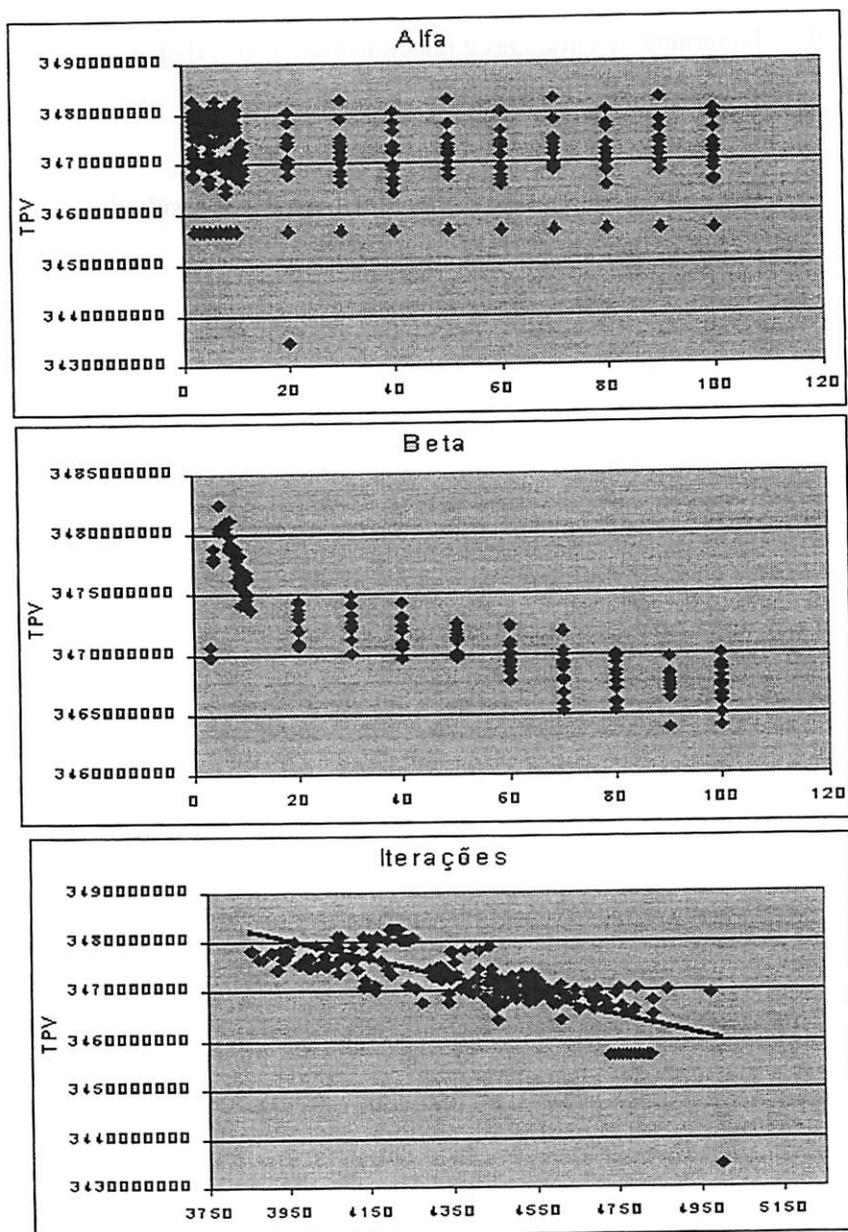


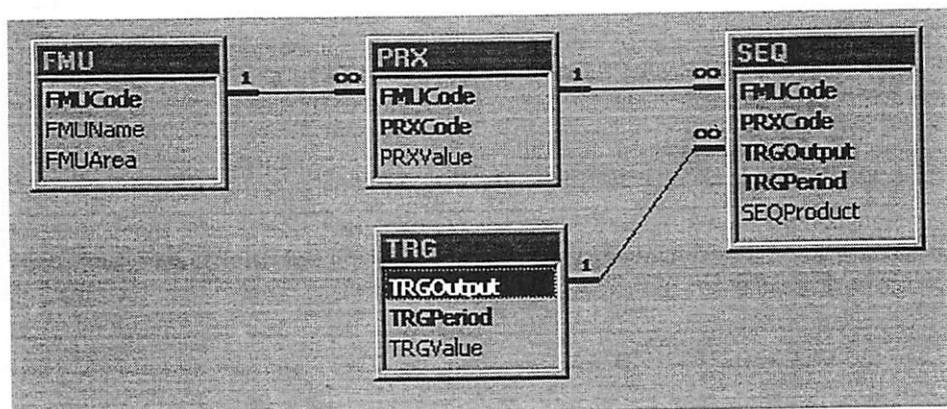
GRÁFICO 16A - Resultados do problema MINESOTA3



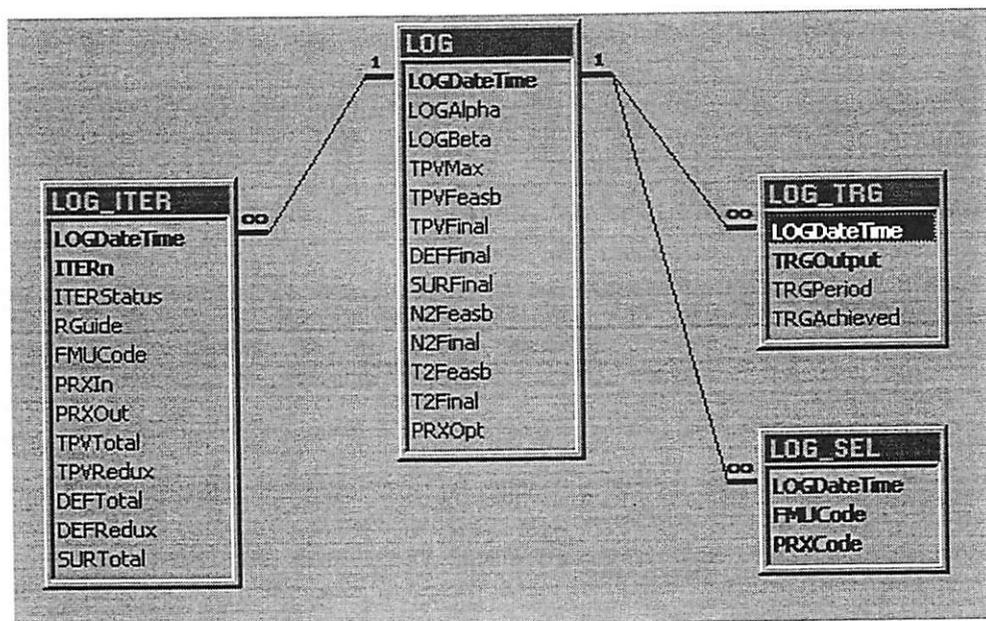
ANEXO B – Modelo de entidades e relacionamentos

	Página
DER 01 – Diagrama de entidades e relacionamentos dos dados necessários à heurística	125
DER 02 – Diagrama de entidades e relacionamentos dos resultados da heurística	126

DER 01 – Diagrama de entidades e relacionamentos dos dados necessários à heurística



DER 02 – Diagrama de entidades e relacionamentos dos resultados da heurística



ANEXO C - Rotinas Principais da Heurística

	Página
Rotina Principal	127
Rotina Secundária	128

Rotina Principal

Initialize NoIterToDo (the number of iterations the user wants to do)

While I < NoIterToDo

- If there are unselected regimes
 - If TotDeficit > 0 *Gray Phase*
 - If time to search in the set of discarded regimes
 - (1) Recalc and choose the best guide in discarded set
 - (4) Exchange the best discarded regime
 - Else
 - (2) Recalc and choose the best guide in unselected set
 - (5) Exchange the best unselected regime
 - Else (If TotDeficit = 0) *Green Phase*
 - If TotalProjectValue can be improved
 - (3) Recalc and choose the best guide in discarded and unselected sets
 - (6) Exchange green phase best regime

End While

Rotinas secundárias

(1) Recalc and choose the best guide in discarded set For every discarded regime

- exchange:
 - regime becomes selected
 - previously selected regime in the respective unit becomes unselected
- calc the deficit reduction caused by the exchange
- calc the guide
 - $\text{guide} = \text{deficit reduction}$
- store if best guide
- undo the exchange

(2) Recalc and choose the best guide in unselected set for every unselected regime

- exchange:
 - regime becomes selected
 - previously selected regime in the respective unit becomes unselected
- calc the deficit reduction caused by the exchange
- calc the total project value reduction
- calc the guide
 - $\text{guide} = \text{Rratio} = \text{DeficitReduction} / \text{TotalProjectValue reduction}$
- store if best guide
- undo exchange

**(3) Recalc and choose the best guide in both sets (discarded and unselected)
for every unselected and discarded regime**

- **exchange:**
 - **regime becomes selected**
 - **previously selected regime in the respective unit becomes unselected**
- **calc the deficit reduction caused by the exchange**
- **calc the total project value reduction**
- **calc the guide**
 - **if deficit > 0**
 - **guide = 0**
 - **else (if deficit = 0)**
 - **guide = TotalProjectValue**
- **store if best guide**
- **undo exchange**

(4) Exchange the best discarded regime with the regime associated to the best guide

- **previously selected becomes discarded**
- **discarded becomes selected**

(5) Exchange the best unselected regime with the regime associated to the best guide

- **previously selected becomes discarded**
- **unselected becomes selected**

(6) Exchange green phase best regime with the regime associated to the best guide

- **If regime is unselected**
 - **selected becomes unselected**
 - **unselected becomes selected**
- **If regime is discarded**
 - **selected becomes discarded**
 - **discarded becomes selected**

CENTRO de DOCUMENTAÇÃO
CEDOC/DAE/UFLA