



Pedro Senna Vieira

**Modelo de otimização estocástica para o planejamento
estratégico da cadeia agrícola de biodiesel**

Dissertação de Mestrado

Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Produção da PUC-Rio como requisito parcial para obtenção do título de Mestre em Engenharia de Produção.

Orientador: Prof. Silvio Hamacher

**Rio de Janeiro
Abril de 2014**



Pedro Senna Vieira

Modelo de otimização estocástica para o planejamento estratégico da cadeia agrícola de biodiesel

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia de Produção da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Silvio Hamacher

Orientador

Departamento de Engenharia Industrial - PUC-Rio

Prof. Fabricio Carlos Pinheiro de Oliveira

Co-orientador

Departamento de Engenharia Industrial - PUC-Rio

Prof. Adriana Leiras

Departamento de Engenharia Industrial - PUC-Rio

Prof. Hugo Miguel Varela Repolho

Departamento de Engenharia Industrial - PUC-Rio

Prof. José Eugenio Leal

Coordenador Setorial do Centro Técnico Científico - PUC-Rio

Rio de Janeiro, 11 de abril de 2014

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Pedro Senna Vieira

Graduou-se em Engenharia de Produção no CEFET/RJ (Centro Federal de Educação Tecnológica Celso Suckow da Fonseca) em 2009. Trabalhou por cerca de dois anos da Empresa Visagio e um ano no Núcleo de Excelência em Otimização (NEXO) da PUC-Rio. Atualmente é professor do Departamento de Engenharia de Produção do CEFET/RJ Uned Nova Iguaçu.

Ficha catalográfica

Senna, Pedro Vieira

Modelo de otimização estocástica para o planejamento estratégico da cadeia agrícola de biodiesel / Pedro Senna Vieira; orientador: Silvio Hamacher. – 2014.

81 f. : il. ; 30 cm

Dissertação (Mestrado em Engenharia Industrial) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2014.

Inclui bibliografia

1. Engenharia industrial – Teses. 2. cadeia de suprimentos. 3. biodiesel. 4. otimização estocástica. 5. Logística. 6. modelo dois estágios. 7. modelo multiestágios I. Hamacher, Silvio. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. III. Título.

CDD: 658.5

Dedico este trabalho a minha família e amigos.

Agradecimentos

Agradeço primeiramente a Deus e aos amigos espirituais. Agradeço à minha família (incluindo meu saudoso pai) e amigos que me deram força durante todo este período. Agradeço também ao orientador Silvio Hamacher e ao Co-orientador Fabrício Oliveira. Agradeço também à CAPES pelo apoio financeiro e ao Guilherme Romeiro e ao Rafael Leão.

Resumo

Vieira, Pedro Senna; Hamacher, Silvio (Orientador). **Modelo de otimização estocástica para o planejamento estratégico da cadeia agrícola de biodiesel**. Rio de Janeiro, 2014. 81p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

O Programa Nacional de Uso e Produção de Biodiesel destaca a produção de biodiesel a partir da mamona como alternativa energética não poluente e como gerador de empregos em regiões carentes. Todavia um empecilho à produção deste biodiesel advém da precariedade da produção da mamona, baseada em agricultores familiares pouco estruturados e com condições logísticas ruins. Assim, este trabalho visa a contribuir à resolução deste problema, procurando otimizar o planejamento estratégico desta cadeia de suprimentos de biodiesel em particular. O objetivo é minimizar os custos totais de transporte e de armazenagem de grãos dos produtores agrícolas às usinas de esmagamento. Uma importante peculiaridade deste problema é a incerteza da produção, que afeta o projeto da cadeia. Desta forma, foi proposto um Modelo de Programação Linear Inteira-Mista (PLIM) Estocástico, com formulação dois estágios e multi-estágio. Cabe ressaltar que este modelo foi testado em um caso real no semiárido brasileiro. Como resultado, são apresentadas as alocações de fluxos e entrepostos de custo mínimo para ambos os modelos. Por fim, é feita uma comparação entre estas formulações ressaltando que o ganho de flexibilidade obtido através do modelo multi-estágio se traduz em um menor custo logístico total.

Palavras-chave

Cadeia de suprimentos; biodiesel; otimização estocástica; modelo dois estágios; modelo multiestágios.

Abstract

Vieira, Pedro Senna; Hamacher, Silvio (Advisor). **Stochastic optimization model to the biodiesel supply chain strategic planning**. Rio de Janeiro, 2014. 81p. MSc Dissertation – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

The Brazilian Program for Biodiesel Use and Production highlights the production of biodiesel from castor seeds, as a non-polluting energy source and as a job generation in poor regions. However, an obstacle to biodiesel production comes from the castor seeds poor production conditions and lack of infrastructure and logistics. This work aims to present a contribution to solve this problem, performing a strategic planning optimization of this biodiesel supply chain. The main objective is to minimize total storage costs and grains transportation to the crushing plant. An important peculiarity of this problem is the production uncertainty, which affects the supply chain design. Thus, we propose a stochastic Mixed Integer Linear Programming (MILP) model with two stage and multi-stage formulations. This model was tested on a real case in the Brazilian's semi-arid region. As a result, in order to obtain the minimum total cost, we present the logistics network flow design and warehouses assignments for both formulations. Lastly, we present a comparison between these formulations highlighting that the flexibility gain provided by the multi-stage model results in a lower total logistic cost.

Keywords

Supply Chain; biodiesel; stochastic optimization; two stage model; multistage.

Sumário

1 Introdução	12
1.1. Relevância da Dissertação	13
1.2. Objetivos	13
1.3. Estrutura da dissertação	14
2 Revisão bibliográfica	15
2.1. Panorama dos combustíveis e dos biocombustíveis	15
2.2. Cadeia de Suprimentos de biodiesel produzido a partir da mamona	16
2.3. A mamona	20
2.4. Projetos de redes	21
2.5. Abordagens para problemas de Projetos de redes	24
2.6. Otimização estocástica	26
2.7. Modelo de Programação Linear Estocástica Dois Estágios	27
2.8. Tipos de Recursos	29
2.8.1. Recurso Simples	30
2.8.2. Recurso Fixo	31
2.8.3. Recurso Completo	31
2.8.4. Recurso Relativamente Completo	31
2.9. Medidas de comparação entre modelos determinísticos e estocásticos	32
2.9.1. Valor Esperado da Informação Perfeita – EVPI	32
2.9.2. Valor da Solução Estocástica – VSS	33
2.10. Modelo de Programação Linear Estocástica de multiestágios	34
2.11. Métodos de Geração de Cenários	36
2.12. Conclusões do capítulo	38
3 Descrição do Problema	39
4 Modelo matemático	43
4.1. Descrição conceitual do modelo matemático	43
4.2. Descrição conceitual e matemática do Modelo Dois Estágios	44
4.2.1. Conjuntos e subconjuntos	45
4.2.2. Parâmetros	47
4.2.3. Variáveis	48
4.2.4. Função objetivo	48
4.2.5. Restrições	49
4.3. Descrição conceitual e matemática do Modelo Três Estágios	51
4.3.1. Conjuntos e subconjuntos	52
4.3.2. Parâmetros	53
4.3.3. Variáveis	53
4.3.4. Função objetivo	54
4.3.5. Restrições	55
5 Estudo de caso	57
5.1. Dados de entrada	57
5.2. Geração de cenários	59
5.3. Resultados - Modelo determinístico (EV)	61

5.4. Resultados - Modelo OE2E	62
5.5. Qualidade de solução do modelo OE2E	64
5.6. Resultados - Modelo OE3E	64
5.7. Conclusões do capítulo	67
6 Conclusões e Estudos futuros	69
6.1. Contribuições da dissertação	70
6.2. Perspectivas de trabalhos futuros	71
7 Referências bibliográficas	72
8 Apêndice	77

Lista de Figuras

Figura 1 - Cadeia do biodiesel, especificamente da mamona. Fonte: Elaborado a partir de Souza (2005)	16
Figura 2 - Produção de biodiesel em m ³	18
Figura 3 - Metodologias para lidar com incerteza. Fonte: Leiras (2011)	25
Figura 4 - Publicações sobre otimização estocástica ao longo dos anos. Fonte: Base SCOPUS	26
Figura 5 – Esquema de decisões	30
Figura 6 - Agricultores enviando diretamente suas produções à usina (Parte 1) e Agricultores enviando suas produções aos entrepostos para que sejam consolidadas e enviadas à usina (Parte 2)	41
Figura 7 - Ilustração dos fluxos. Setas azuis fluxos primários e setas vermelhas fluxos secundários	41
Figura 8 - Questões tributárias gerando dificuldades operacionais	42
Figura 9 - Modelo dois estágios	45
Figura 10 - Modelo Três Estágios	51
Figura 11 - Dados de produção de mamona no Brasil. Fonte: CONAB (2012)	60
Figura 12 - Desvios percentuais da produção	60
Figura 13 - Histograma dos desvios percentuais	61
Figura 14 - Fluxos e entrepostos para modelo determinístico	62
Figura 15 - Árvores de cenários para modelo OE2E	64
Figura 16 - Exemplo do cálculo da árvore de cenários para o modelo OE3E	66
Figura 17 - Rede logística - Cenários 1; 1.1 – PI, RN, PB, PE e C	77
Figura 18 - Rede logística - Cenários 2; 2.1 – PI, RN, PB, PE e CE	78
Figura 19 - Rede logística - Cenários 3; 3.1 – PI, RN, PB, PE e CE	78
Figura 20 - Rede logística - Ramo 1; 1.1 - BA e MG	79
Figura 21 - Rede logística - Ramo 2; 2.1 - BA e MG	80
Figura 22 - Rede logística - Ramo 3; 3.1 - BA e MG	80

Lista de Tabelas

Tabela 1 – Maneiras de produzir biodiesel. Fonte: EAI (2013).	17
Tabela 2 - Conjuntos	46
Tabela 3 - Subconjuntos	46
Tabela 4 - Parâmetros do Modelo Dois Estágios	47
Tabela 5. Variáveis	48
Tabela 6 - Conjuntos	52
Tabela 7 - Variáveis	53
Tabela 8 - Nós do modelo	57
Tabela 9 - Custos de carregamento	58
Tabela 10 - Custos de transporte	58
Tabela 11 - Estimativas de produção por estado	59
Tabela 12 - Capacidades das instalações	59
Tabela 13 - Custos de instalação	59
Tabela 14 - Entrepostos selecionados após a otimização	63
Tabela 15 - Comparativo de entrepostos entre modelos OE3E e OE2E.	67
Tabela 16 - Funções Objetivo e indicadores	68

Introdução

O biodiesel pode substituir total ou parcialmente o óleo diesel de petróleo em motores automotivos. Sua utilização possibilita a economia de divisas com a importação de petróleo e óleo diesel, além de gerar empregos em áreas geográficas menos atraentes para outras atividades econômicas, e assim, promover inclusão social (Ferreira e Borenstein, 2007).

O mercado de biodiesel tem crescido de forma significativa nos últimos anos, na medida em que este combustível vem se tornando uma importante alternativa ao petróleo. Lançado em 2004, o Programa Nacional de Uso e Produção de Biodiesel (PNPB) visa a promover o desenvolvimento regional em áreas carentes por meio da inclusão de agricultores familiares na cadeia produtiva (PNPB, 2013). Neste programa, destaca-se a produção de biodiesel a partir da mamona fornecida por pequenos produtores agrícolas da região nordeste. Todavia, estes agricultores se encontram dispersos em uma região extensa, com acesso por uma rede rodoviária precária, o que gera um importante problema de otimização logística dentro desta cadeia de suprimentos. Assim, uma das principais questões é a localização ótima de entrepostos de forma a centralizar as entregas destes pequenos agricultores para as usinas de esmagamento da mamona.

Neste trabalho é proposto um modelo de otimização para apoiar o planejamento estratégico da cadeia produtiva de biodiesel produzido através da mamona. Mais especificamente, o presente trabalho visa a propor um modelo de localização de entrepostos e alocar fluxos de forma a minimizar o custo total da rede logística. Trabalho semelhante já havia sido feito por Leão *et. al.* (2011), onde os autores apresentam uma metodologia para conceber uma cadeia de suprimentos otimizada a partir da agricultura familiar.

O modelo de Programação Linear Inteira-Mista (PLIM) aplicado em um caso real serviu de base para a tomada de decisões estratégicas no que diz respeito ao projeto desta rede logística. Ao longo do trabalho percebeu-se que havia uma grande incerteza com relação às safras de mamona. Tal incerteza é um problema para o dimensionamento da rede logística de transporte da mamona, portanto, o

projeto da rede logística deve considerar as incertezas para não subestimar nem superestimar as instalações necessárias. Uma abordagem para tratar a incerteza é fazendo uso da Programação Estocástica. A partir do modelo (determinístico) criado, vislumbrou-se a criação de um modelo que representasse com maior precisão a incerteza e as consequências das tomadas de decisão ao longo do tempo. Assim, o modelo PLIM previamente criado foi aprimorado e se transformou em um modelo multi-estágios estocástico.

1.1

Relevância da Dissertação

A dissertação busca contribuir, principalmente, em dois aspectos, no âmbito acadêmico busca trazer uma aplicação com dados reais do problema logístico do esmagamento de grãos de mamona utilizando a Programação Estocástica Linear Inteira Mista. Este trabalho também agrega valor acadêmico em termos de metodologias para geração dos cenários. Na literatura é comum encontrar problemas de otimização estocástica onde não são feitas considerações sobre como são gerados estes cenários. A falta de uma metodologia para geração de cenários pode gerar alguns problemas. Por exemplo, a possibilidade de aumentar a complexidade do problema sem que se amplie a quantidade de informação útil gerada para a resolução do problema. Pode-se também acrescentar o fato de que não há garantia de que tais cenários representem de maneira precisa a realidade estudada.

No âmbito prático, a dissertação busca oferecer a possibilidade de resolver problemas semelhantes utilizando um modelo que permite a consideração do efeito da incerteza ao longo do tempo no processo de tomada de decisão.

1.2

Objetivos

Este trabalho tem como objetivo principal apresentar uma aplicação prática de um modelo PLIM estocástico com resultados obtidos a partir de dados reais coletados e a comparação dos modelos dois e multi-estágios. O trabalho pretende mostrar o ganho que se obtém ao refinar o modelo determinístico com a

incorporação de mais estágios e cenários para representar as incertezas da safra e mostrar que com esta metodologia é ampliada a confiabilidade da solução encontrada, pois, o modelo é otimizado considerando variabilidade dos dados. Isso representa uma vantagem sobre o modelo determinístico que gera uma solução que é válida apenas para aquele exato conjunto de dados, e que pode ser inviável. O modelo estocástico encontra uma solução que não é ótima para um cenário especificamente, porém, razoavelmente boa para todos.

Como objetivo secundário, o trabalho se propõe a oferecer um método estruturado para a geração de cenários, visando a representar a incerteza de forma mais precisa.

1.3

Estrutura da dissertação

A dissertação está organizada da seguinte forma: a seção 2 mostra a revisão de literatura que fornece o embasamento teórico para os conceitos utilizados no estudo de caso, mostrando o contexto amplo das premissas que são assumidas no presente problema, a seção 3 fornece uma descrição detalhada do problema abordado descrevendo as características da cadeia de suprimentos do biodiesel baseada na mamona. Tais características são importantes, pois influem diretamente no desenho logístico e a opção pela utilização da incerteza, a seção 4 apresenta o modelo matemático, restrições, parâmetros, variáveis e função objetivo, a seção 5 apresenta os principais resultados encontrados após a solução do modelo e a seção 6 apresenta as conclusões e propostas de estudos futuros.

2

Revisão bibliográfica

Nessa análise buscou-se identificar os trabalhos que abordam temas como Projeto de Redes, onde é revista a importância do tópico para as Cadeias de Suprimentos; as abordagens utilizadas para modelagem e solução de problemas relacionados a Projetos de Redes; a descrição matemática da Programação Estocástica de dois estágios; o modelo de Programação Estocástica multi estágios e os métodos de geração de cenários.

Não houve a pretensão de ser exaustivo, mas sim, analisar aqueles trabalhos que possibilitem ao leitor o que vem sendo feito para estudar o tema e as técnicas que têm sido aplicadas em problemas semelhantes.

2.1

Panorama dos combustíveis e dos biocombustíveis

A relevância do biodiesel vem sendo destacada na literatura devido à sua importância, quer seja econômica ou ambiental. O biodiesel é originário de uma fonte renovável, é biodegradável e não tóxico, além disso, em termos de emissões gasosas, possui melhor desempenho que os derivados de petróleo (Zhang *et al.* 2003).

Desta forma, tais qualidades fazem o biodiesel se destacar no cenário de combustíveis como uma boa alternativa aos combustíveis baseados em petróleo o que tem acarretado a ampliação de seu uso em muitos países, principalmente em áreas mais sensíveis às questões ambientais. (Körbitz, 1999).

Assim, pode-se dizer que a crescente produção de biodiesel, e seu uso como substituto aos combustíveis fósseis, tem se tornado um fenômeno global, ainda que com diferentes motivações. Citando como exemplo os Estados Unidos, pode-se notar em sua política a preocupação com a estabilização de uma matriz energética que seja menos dependente da importação de petróleo, especialmente porque esta *commodity*, em geral, é vendida por países politicamente instáveis. Com relação aos europeus, é possível sinalizar que o principal fator motivacional

é o de assegurar o crescimento econômico aliado à sustentabilidade ambiental através da meta de substituição dos combustíveis fósseis e redução das emissões de outros combustíveis (Van Dyne *et al.*, 1996).

Assim, considerando-se o cenário de crescimento previsto para os próximos anos, a fim de que o sucesso do biodiesel seja mantido, faz-se necessário que os investimentos cresçam na mesma proporção, quer sejam investimentos em instalações, em desenvolvimento de cadeia de suprimentos ou em processamento de matérias-primas.

2.2

Cadeia de Suprimentos de biodiesel produzido a partir da mamona

O fato da produção de oleaginosas ser em grande parte baseada em agricultura familiar gera dificuldades que a pesquisa operacional pode, em grande parte, contribuir para uma solução que diminua os custos da operação. A Figura 1 exemplifica a cadeia de suprimentos de biodiesel.

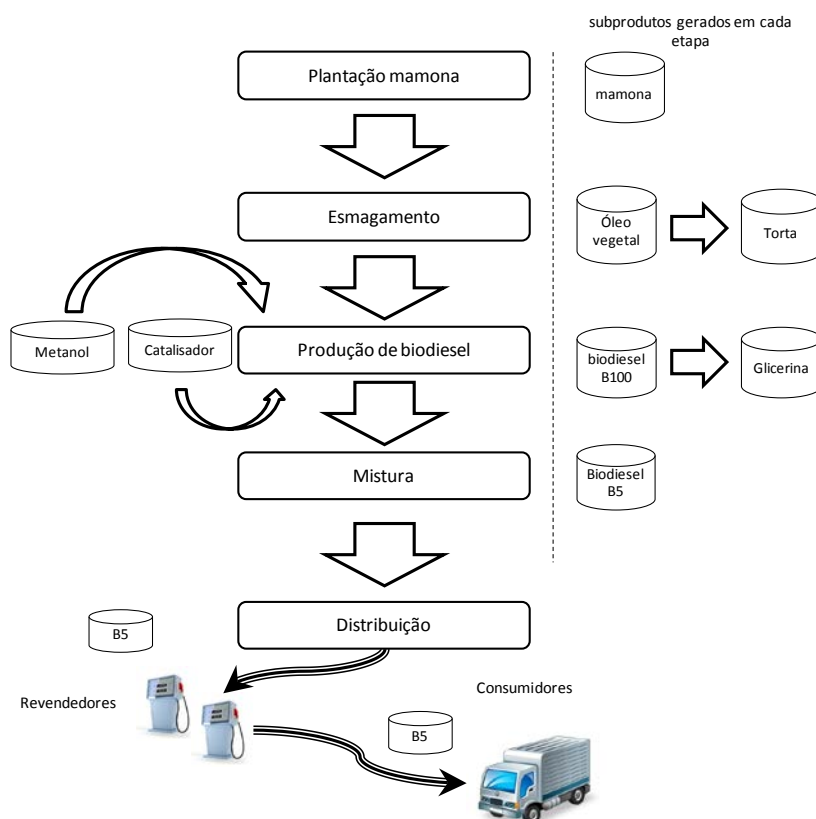


Figura 1 - Cadeia do biodiesel, especificamente da mamona. Fonte: Elaborado a partir de Souza (2005)

Para se produzir biodiesel, o óleo retirado das plantas é misturado com álcool (ou metanol) e depois estimulado por um catalisador. O catalisador é um produto usado para provocar uma reação química entre o óleo e o álcool. Depois o óleo é separado da glicerina (usada na fabricação de sabonetes) e filtrado (Biodiesel BR, 2013).

O biodiesel B100 é o biodiesel puro sem ainda ser misturado com o diesel mineral (Biodiesel BR, 2013). A produção de glicerina no Brasil, da ordem de 30 mil toneladas por ano, é basicamente absorvida pelo mercado nacional, na fabricação de cosméticos e farmacêuticos. (EMBRAPA, 2007).

Outra aplicação da glicerina na área petroquímica é como insumo na produção de acrilatos e outros derivados, gerando propeno, produto de demanda crescente no mercado brasileiro de plásticos (EMBRAPA, 2007). Além disso, a produção de intermediários para a fabricação de plásticos, como o propanodiol, pode ser realizada a partir do beneficiamento da glicerina (EMBRAPA, 2007).

A Tabela 1 mostra as diferentes gerações de tecnologia para a produção de biocombustíveis. No Brasil a cadeia do biodiesel é classificada como de primeira geração.

Tabela 1 – Maneiras de produzir biodiesel. Fonte: EAI (2013).

<i>Primeira geração</i>	<i>Matéria - Prima</i>	<i>Tecnologia</i>	<i>Exemplo</i>
Primeira geração de biocombustíveis	Açúcar, amido, óleos vegetais ou gordura animal	. Prensagem a frio/quente, extração e transesterificação . Prensagem a frio/quente, extração e purificação . Hidrólise e fermentação	Bioetanol, óleo vegetal, biodiesel, biogás
Segunda geração de biocombustíveis	Palha de trigo, milho, madeira, resíduos sólidos, amendoim, mamona, cana-de-açúcar	. Hidrólise e fermentação . Pirólise, gaseificação e metanação . Transesterificação	Bioetanol celulósico, Biocombustíveis sintéticos, Biohidrogênio e biodiesel.
Terceira geração de biocombustíveis	Algas	. Pirólise, gaseificação e Reação de mudança água/gás . Transesterificação . Fermentação	Óleo vegetal, biodiesel

Segundo a Agência Nacional de Petróleo (ANP, 2013), a produção de biodiesel no país em 2012 foi de 2.717.483 m³. Na Figura 2 é possível visualizar a produção brasileira nos últimos anos.




Figura 2 - Produção de biodiesel em m³

Especificamente, a partir de 2005, a produção começou a crescer a taxas maiores, muito em função da lei 11.097 de 13 de janeiro de 2005 (Senado Brasileiro, 2013) que fixa em 5%, em volume, o percentual mínimo obrigatório de adição de biodiesel ao óleo diesel comercializado ao consumidor final em qualquer parte do território nacional.

O governo federal lançou o selo combustível social (selo verde) visando ao desenvolvimento da agricultura familiar. Este selo é um conjunto de medidas específicas para estimular a inclusão social na agricultura, estimulando as empresas produtoras de biodiesel a apresentarem projetos que busquem incluir a agricultura familiar em suas cadeias produtivas ou garantam a compra de matéria-prima oriunda deste tipo de agricultura. Em contrapartida, a empresa pode usufruir de uma série de vantagens, entre elas, estar apta a participar de leilões de compra de biodiesel para o mercado interno brasileiro, bem como acesso de melhores condições de financiamento junto ao BNDES. (Biodiesel BR, 2013).

Atualmente, o parque industrial do Brasil está voltado basicamente para extração de óleo de soja e reflete o desenvolvimento desta cadeia produtiva, sendo a realidade bastante diferente para outras oleaginosas. No entanto, no que diz respeito à agricultura familiar para a produção de biodiesel no Brasil, o suprimento de matérias-primas vêm se estabelecendo com duas oleaginosas: mamona e girassol (Leão, 2009).

No Brasil, a estratégia traçada consiste em estabelecer a participação de pequenos produtores rurais como pilares do projeto de produção do biodiesel. De

um modo geral, a agricultura familiar se caracteriza principalmente pela dispersão territorial, pequena propriedade e pela reduzida escala de produção (Leão, 2009). Segundo dados do DIEESE (2008), a cadeia produtiva agrícola familiar é responsável por 19% do PIB agrícola total do país.

Além do consenso de que o principal entrave para a consolidação da cadeia produtiva de biodiesel no semiárido seja o baixo volume de produção, ainda não foram equacionadas questões relativas à logística de transporte de matérias-primas e biodiesel, bem como as relacionadas à localização de unidades de armazenamento e produção (Azvaradel, 2008). Cabe ressaltar que em grande parte dos casos, é necessário que o produtor da oleaginosa percorra grandes distâncias para recolher pequenos volumes por modal rodoviário, sendo que as péssimas condições das estradas acarretam um aumento importante no custo final do produto (Azvaradel, 2008). Além disso, a capacidade de armazenagem instalada e suas condições também constituem uma fragilidade da cadeia produtiva de mamona, particularmente em regiões de pouca tradição produtiva como o semiárido nordestino (Vieira, 2006).

Segundo Leão *et al.* (2011), apesar da importância do tema do projeto de cadeia de biocombustíveis, poucos são os autores que se debruçam efetivamente sobre o tema, geralmente tratando-o como um problema de localização capacitada.

Sotoft *et al.* (2010) utilizam simulação de processos para avaliar a viabilidade econômica da produção de biodiesel a partir de dois processos químicos distintos. Haas *et al.* (2006) também utilizam simulação para estimativa de custos em uma planta de produção.

Praça *et al.* (2004) elaboraram um modelo de programação linear para estudo preliminar da localização de esmagadoras no estado do Ceará, indicando a relevância das análises para a sustentabilidade da produção de biodiesel com base na agricultura familiar utilizando o Problema de Localização Capacitado (PLC) que Praça (2003) já havia utilizado para localizar centros de distribuição secundária de gás natural.

Oliveira *et al.* (2010) resolveram o problema utilizando a abordagem de otimização robusta, em uma cadeia considerando zonas produtoras, usinas esmagadoras e usinas de biodiesel. Entre as várias decisões tomadas neste problema incluem-se a localização das usinas esmagadoras e a suas capacidades.

Leduc *et al.* (2009) e Pinedo e Abreu (2011) usam programação linear inteira mista (PLIM) para determinar o número ótimo e a localização de plantas de biodiesel.

2.3

A mamona

A mamona (*Ricinus communis L.*) possui um óleo com diversas utilizações industriais, desde próteses ósseas até lubrificantes de motores. A atual legislação que institui a adição de biodiesel ao diesel criou grande expectativa na produção de mamona, visto ser um dos óleos indicados para a produção deste, gerando uma demanda por cultivares com adaptação em regiões onde o cultivo da mamona não é tradicional (EMBRAPA, 2007).

Comercialmente, o óleo de mamona possui aplicações industriais e medicinais. Da industrialização da mamona, extraem-se o óleo (seu principal produto) e o subproduto nomeado torta (Alves *et al.*, 2004).

A torta de mamona, produzida durante a extração do óleo, é um importante subproduto da cadeia produtiva da mamona. Seu uso predominante é como adubo orgânico, já que se trata de uma rica fonte de nitrogênio. (EMBRAPA, 2007).

No mercado internacional, a comercialização da mamona pode ser feita tanto na forma bruta e de pouco valor agregado (mamona em baga), quanto em formas intermediárias (óleo bruto ou refinado) ou através da exploração de seus derivados de alto valor agregado (ácido graxo destilado de óleo de mamona desidratado, óleo de mamona hidrogenado, óleo de mamona sulfuricinado, ácido 12-hidróxido esteárico e outros, com usos diferenciados como poliuretanos, resinas plásticas, etc.).

Nestes mercados internacionais, o óleo é o principal produto comercializado, constituindo-se em matéria-prima industrial utilizada para obtenção de inúmeros produtos (EMBRAPA, 2007).

A mamona possui ciclo médio de 250 dias entre o plantio e a maturação dos últimos cachos. O cacho principal tem a maturação em torno de 90 dias (quando se realiza a primeira colheita, o segundo e terceiro cachos em torno de 120-180 dias (2ª colheita) e, finalmente, os demais cachos em torno de 220 dias quando é realizada a terceira colheita (EMBRAPA, 2007).

A época de plantio está relacionada à incidência de pragas, doenças, plantas daninhas e à utilização do substrato ecológico, em especial os fatores hídricos, térmicos e luminosos que podem interferir na emergência e na produtividade da lavoura. (EMBRAPA, 2007)

A mamoneira é tida como tolerante à seca. Há referências de bons rendimentos com chuvas de 375 a 500 mm anuais, no entanto, tanto a ausência como o excesso de chuvas no período da floração, podem reduzir a produtividade da planta (Weiss, 1983). Ela produz economicamente em áreas onde a precipitação pluvial mínima até o início da floração seja em torno de 400 mm (Souza e Távora, 2006).

A consideração sobre as chuvas é determinante para o trabalho, pois, o regime pluviométrico é um dos fatores principais de variação na produção total de mamona.

2.4

Projetos de redes

O planejamento de redes logísticas se constitui em um problema crucial para os profissionais de logística e *Supply Chain*, pois impacta diretamente no funcionamento e na eficiência de uma cadeia de suprimentos. O desenho de uma cadeia de suprimentos pode gerar impactos positivos ou negativos no custo logístico global e no nível de serviço oferecido aos clientes.

Segundo Ballou (2006) a localização de instalações na rede logística constitui uma das principais questões de planejamento estratégico logístico para muitas empresas. Para Jayaraman (1998), modelos matemáticos são criados para endereçar questões do tipo “Quantas instalações devem ser posicionadas?”, “Onde cada instalação deve ser localizada?”, “Como a demanda de cada cliente deve ser alocada às instalações?”. Comumente, estudando o tema são utilizados os termos “instalações” ou “facilidades”, mais similar ao termo em inglês “*facility*”. Jayaraman (1998) afirma que o termo facilidade, no seu sentido mais amplo, inclui entidades como fábricas, escolas, armazéns, revendedores, hospitais, entre outros.

Segundo Wanke (2004), uma rede de distribuição pode ser composta por diversos tipos de instalações, como fábricas, armazéns, centros de distribuição,

terminais de cargas, lojas, centros de serviços e mercados consumidores, entre outros.

Para Wanke & Zinn (2004), os profissionais de logística devem tomar decisões estratégicas para gerenciar de incertezas, serviços ao cliente e para avaliar custos na rede de distribuição. Ainda segundo os autores, a definição da política mais apropriada para o atendimento constitui um dos fatores críticos de sucesso.

Para a determinação do seu posicionamento logístico, uma empresa deve tomar decisões relativas ao dimensionamento da rede de instalações. O dimensionamento da rede de instalações envolve a determinação do número de instalações, sua localização e quais os mercados que elas servirão (Fleury, Wanke e Figueiredo, 2000).

Ballou (2006) afirma que os problemas de localização de instalações se enquadram em um número limitado de categorias, abrangendo as seguintes possibilidades:

- Determinação dos fatores preponderantes, ou seja, se há um fator mais crítico que todos os outros, como o lucro de determinada região ou acessibilidade mais fácil para transportes;
- Determinação do número de instalações a serem abertas;
- Determinação das possíveis localidades, ou seja, se há locais predeterminados para a localização ou se o método de cálculo determinará a melhor localidade a partir de uma região em um plano/espço;
- Escolha do grau de agregação dos dados;
- Escolha do horizonte de tempo.

Lee (2002) afirma que ao posicionar instalações, devem ser considerados os objetivos da organização, as necessidades do *core business* e a fonte de valor. Nutt (2002) ainda menciona contexto de mercado, stakeholders, e fatores culturais. Cotts (1999) cita fatores como tamanho da organização que posicionará as facilidades e se tais instalações são de sua posse.

Para Lacerda (2000), tipicamente os problemas de localização apresentam alta complexidade e são intensivos no uso de base de dados. Isso ocorre porque as variáveis dos problemas se influenciam mutuamente, gerando *trade-offs* e o

número de alternativas a serem analisadas é muito grande, mesmo para problemas de pequeno porte.

Hoffman e Schniederjans (1994) propõem um modelo de dois estágios que combina técnicas de Gerenciamento Estratégico, *Management Science* e Programação por Objetivos (*Goal Programming*).

Chaudhry *et al.* (1995) abordam o problema através do uso da técnica da *p*-mediana primeiramente descrito por Hakimi (1965). Os Autores analisam as diferenças entre a resolução do problema com e sem restrições de distância máxima.

Utilizando o método AHP (*Analytical Hierarchy Process*) Yang e Lee (1997) apresentam um modelo de decisão para a seleção do local das instalações. O modelo requer uma proposta prévia de locais que serão avaliados segundo critérios qualitativos e quantitativos.

Jayaraman (1998) desenvolve um modelo logístico multi-período. Neste trabalho, o autor aloca armazéns para minimizar o custo logístico total da rede e propõe um método de solução heurístico para resolver a relaxação lagrangeana proposta. A ideia do algoritmo é a cada iteração gerar uma solução viável para o problema relaxado, e ao final, escolher a melhor solução viável encontrada pela heurística.

Canel e Das (2002) apresentam um modelo de localização de instalações de custo mínimo que integra decisões estratégicas de marketing e manufatura onde o objetivo é a maximização do lucro. O principal objetivo do modelo é decidir em que países localizar instalações, em qual período de tempo, a quantidade a ser produzida em tais instalações e quais destas instalações irão atender os clientes do mercado global. A decisão do país adequado para localizar tais instalações depende do potencial de marketing e manufatura destes países. As decisões de produção dependem da demanda dos clientes nestes diferentes mercados e a decisão de distribuição depende entre outros fatores da distância destes clientes das instalações.

Chotipanich (2004) em seu trabalho "*Positioning facility management*" propõe um trabalho qualitativo onde são indicados quais fatores devem ser considerados em qualquer framework para determinar o posicionamento de instalações. Basicamente, o autor divide estes fatores em internos e externos. Dentre os fatores internos são citados: características organizacionais,

características específicas das instalações e setor do negócio. Entre os fatores externos encontram-se: fatores econômicos, sociais, ambientais, regulatórios (legislações), contexto mercadológico do gerenciamento de instalações e cultura local.

Kaveh e Sharafi (2008) analisam o problema de localizar p -medianas em uma rede logística. Os autores afirmam que achar medianas em um grafo é considerado um problema NP – difícil, assim sendo, algoritmos exatos só podem ser aplicados em problemas pequenos. Assim, os autores utilizam o algoritmo de Colônia de Formigas para resolver este problema.

Mais recentemente, Zhang *et al.* (2012) analisam o problema de localização de instalações considerando a possibilidade da instalação “falhar” e ter que ser desativada. Entre tais falhas ele inclui, por exemplo, o caso de uma grande contaminação em um hospital. Os autores ainda afirmam que há a possibilidade de falha nos arcos, no caso os fluxos de distribuição, ou dos nós (hospitais, armazéns e etc.) Para isso os autores utilizaram um programa estocástico bi-nível de cobertura máxima que determina as localizações através de análise de cenários e otimização robusta.

2.5

Abordagens para problemas de projetos de redes

Nesta seção são apresentados os métodos de modelagem utilizados no estudo de caso, que consiste no modelo de programação estocástica de dois e três estágios.

Para Ribas (2008) os problemas de otimização estocástica tentam resolver de forma eficiente situações do mundo real através de modelos matemáticos e que comumente estão associados a parâmetros incertos, como produção, demanda, custos e preços.

Galbraith (1969) define incerteza como a diferença entre a quantidade de informação necessária para efetuar uma tarefa e a quantidade já possuída. No mundo real, há diversas formas de incerteza que afetam processos produtivos. Segundo Ribas (2008) entre as abordagens mais comumente encontradas para tratar estas incertezas podem ser destacadas a programação estocástica, a programação robusta e a programação *fuzzy*.

Muitos modelos de programação estocástica são inicialmente formulados como modelos determinísticos. Ribas (2008) complementa afirmando que o modelo determinístico permite calcular a solução ótima para cada um dos cenários separadamente, enquanto que o modelo estocástico considera o conjunto de todos os cenários simultaneamente, cada um com uma probabilidade de ocorrência associada. Pode-se dizer que na otimização estocástica não será encontrado o ótimo para cada cenário individualmente, mas sim uma solução razoavelmente boa para todos, ainda que não ótima individualmente para cada um dos cenários.

Leiras (2011) afirma que a abordagem estocástica lida com problemas de otimização onde os parâmetros assumem uma distribuição de probabilidade discreta ou contínua e podem ser divididos em modelos de recurso e modelos probabilísticos. Mais detalhadamente, tem-se:

- Modelos de recurso (*recourse models*): esta abordagem foi originalmente proposta por Dantzig (1955) e Beale (1955) para problemas de programação estocástica de dois estágios, podendo ser estendida para múltiplos estágios.
- Modelos probabilísticos (*chance-constrained programming*): apresentados por Charnes e Cooper (1959), permitem que algumas restrições de segundo estágio sejam expressas em termos de declarações probabilísticas sobre as decisões de primeiro estágio.

Leiras (2011) resume as principais abordagens de lidar com a incerteza:



Figura 3 - Metodologias para lidar com incerteza. Fonte: Leiras (2011)

2.6

Otimização estocástica

Nos últimos anos, a otimização estocástica vem aumentando seu uso, o que se confirma ao efetuar uma busca pelo tema na base SCOPUS. Os resultados são mostrados pelo gráfico da Figura 4:




Figura 4 - Publicações sobre otimização estocástica ao longo dos anos.

Fonte: Base SCOPUS

Para Kaut e Wallace (2007), tal popularidade foi permitida devido ao avanço na potência computacional, que possibilitou adicionar estocasticidade aos modelos determinísticos de outrora. Novamente o gráfico demonstra esse efeito com a explosão do número de publicações principalmente a partir dos anos 2.000 quando o acesso a computadores aumentou de forma significativa. Ainda para os autores, um modelo de programação estocástica pode ser visto como um programa matemático onde há incerteza em alguns parâmetros. Em vez de valores individuais, estes parâmetros são descritos como distribuições probabilísticas (para o caso de um período de tempo) ou processos estocásticos (para o caso de multiperíodos).

2.7

Modelo de programação linear estocástica dois estágios

O modelo de programação estocástica mais aplicado e estudado é o de programação linear de dois estágios (Shapiro e Philpott, 2007). Tal visão é corroborada por Nagar e Jain (2008) que testaram a programação dois estágios em um conjunto de problemas e comparam com uma abordagem multiestágios. Nagar e Jain (2008) afirmam ainda que, apesar da abordagem multiestágios permitir um maior detalhamento do problema, a abordagem dois estágios é mais utilizada.

Além das aplicações práticas, tais modelos possuem definições matemáticas e conceituais que devem ser compreendidas antes da implementação computacional. Neste sentido, para Ribas (2008) o modelo de dois estágios, como o próprio nome sugere, divide as variáveis de decisão em dois estágios. As variáveis de primeiro estágio devem ser decididas antes da realização de incertezas. As variáveis de segundo estágio são utilizadas como medidas de correção contra qualquer inviabilidade que tenha surgido após a realização de incertezas. No quesito aplicações práticas, se pode citar Falasca e Zobel (2011) que utilizam um modelo de programação estocástica dois estágios com recurso para otimizar as compras de uma cadeia de suprimentos de ajuda humanitária. Oliveira e Hamacher (2012) utilizam o modelo dois estágios para resolver o problema de planejamento de investimentos de uma cadeia de suprimentos de uma companhia de petróleo. Miranda *et al.* (2011) usam a programação não – linear inteira mista dois estágios sob incertezas para redesenhar a rede de transporte aérea brasileira. Serpa e Hamacher (2012) utilizam um modelo linear inteiro misto de dois estágios para apoiar a decisão de compra de dutos flexíveis e umbilicais, que são equipamentos que fazem a interligação de equipamentos submarinos às Unidades Estacionárias de Produção (UEP's). Tal problema faz parte da atividade de exploração e produção de petróleo do segmento *off-shore* no Brasil.

O modelo de programação estocástica de dois estágios pode ser formulado como:

$$\begin{aligned} \text{Min}_{x \in X} \left\{ Z(x) = C^T x + E_{\xi} [Q(x, \xi)] \right\} \\ \text{S.A. } Ax \leq b \\ x \geq 0 \end{aligned} \quad (2.1)$$

Onde $Q(x, \xi)$ é o valor ótimo do problema de segundo estágio.

$$\begin{aligned} & \text{Min}_{x \in X} q^T y \\ & \text{S.A. } Wy \leq h - Tx \\ & y \geq 0 \end{aligned} \quad (2.2)$$

$x \in R^n$ é o vetor das variáveis de decisão de primeiro estágio. $C \in R^n$, $b \in R^m$ e $A \in R^{m \times n}$, são dados associados ao problema de primeiro estágio, $y \in R^m$ é o vetor das variáveis de decisão de segundo estágio e $\xi = (q, T, W, h)$ contém os dados para o problema de segundo estágio que podem ser variáveis aleatórias com distribuições de probabilidade conhecidas.

Segundo Kaut e Wallace (2007), exceto para casos realmente muito simples, este modelo não pode ser resolvido com distribuições contínuas, portanto, os métodos de solução requerem distribuições discretas. Outra consideração importante é o fato de que a cardinalidade do suporte das distribuições discretas é limitada pela potência computacional disponível e a complexidade do modelo de decisão. Além disso, em muitas aplicações práticas, os parâmetros incertos devem ser discretizados. Essa discretização é chamada de Árvore de Cenários ou Árvore de Eventos.

Assume-se aqui, então, que cada realização $\xi_k, k = 1, \dots, \omega$ tenha probabilidades $p_k, k = 1, \dots, \omega$. Assim, o valor esperado $E[Q(x, \xi)]$ pode ser escrito como:

$$E[Q(x, \xi)] = \sum_{\omega=1}^{\Omega} p_{\omega} Q_{\omega}(x, \xi_{\omega}) \quad (2.3)$$

Considerando-se o modelo discreto, pode-se reescrevê-lo da seguinte forma:

$$\begin{aligned} & \text{Min}_{x \in X} \left\{ Z(x) = c^T x + \sum_{\omega=1}^{\Omega} p_{\omega} Q_{\omega}(x, \xi_{\omega}) \right\} \\ & \text{S.A. } Ax \leq b \\ & x \geq 0 \end{aligned} \quad (2.4)$$

Onde $Q(x, \xi_{\omega})$ é o valor ótimo do problema de segundo estágio para cada realização $\omega = 1, \dots, \Omega$

$$\begin{aligned}
& \text{Min}_{x \in X} q_{\omega}^T y_{\omega} \\
& \text{S.A. } W_{\omega} y_{\omega} \leq h_{\omega} - T_{\omega} x \\
& \quad y_{\omega} \geq 0
\end{aligned} \tag{2.5}$$

No primeiro estágio são tomadas decisões do tipo aqui e agora, com base na informação que se possui hoje. Essas decisões correspondem ao vetor x . No segundo estágio, quando as informações ξ já estão disponíveis são tomadas decisões sobre os valores do vetor y .

No primeiro estágio efetua-se a minimização do custo de $c^T x$ mais o valor esperado do problema de segundo estágio. As decisões tomadas no problema de segundo estágio consistem em uma “correção de rumo”, em uma correção das decisões tomadas antes da incerteza ser revelada.

As restrições que garantem que as decisões de primeiro estágio dependam apenas da informação disponível até aquele momento são chamadas de restrições de não-antecipatividade. Este conceito é aprofundado na seção 2.8.

No problema de dois estágios isto implica que a decisão x independe das realizações do segundo estágio, sendo assim o vetor x é o mesmo para todos os possíveis eventos que venham a ocorrer no segundo estágio do problema (Birge e Louveaux, 1997).

2.8

Tipos de recursos

Apesar de não ser objetivo do trabalho se aprofundar no tema recurso, o assunto precisa ser introduzido, tendo em vista que as definições matemáticas dos problemas de dois e multiestágios se utilizam deste conceito. Primeiramente vale esclarecer uma questão de semântica, no português e em problemas deste tipo geralmente a palavra recurso indica matérias-primas, operários, ou seja, recurso no sentido de uma entidade que viabiliza uma determinada tarefa. O recurso aqui é um termo que se refere à oportunidade de se adaptar a solução dada a realização da incerteza (Higle, 2005). Modelos de recurso são o resultado de um conjunto de decisões que devem ser tomadas antes que informações relevantes sobre as incertezas estejam disponíveis (Higle, 2005).

Higle (2005) afirma que cada problema de recurso pode ser caracterizado por sua árvore de cenários e suas restrições de não antecipatividade. Um cenário é uma realização completa e específica da incerteza. A autora afirma ainda que dependendo da forma com que o problema é estruturado pode ser necessário incluir condições específicas para que a sequência de decisões seja tomada de acordo com a estrutura de informações associadas com a árvore de cenários. Tais condições são conhecidas como restrições de não antecipatividade.




Figura 5 – Esquema de decisões

Em Higle (2005) pode-se observar a classificação em três tipos de recurso que serão expostos nos itens seguintes.

2.8.1

Recurso Simples

Considerando a formulação do problema de dois estágios visto nas equações eq.(2.3) e eq.(2.5). O Recurso é considerado simples quando a matriz W de coeficientes das restrições forma uma matriz identidade tal que:

$$\begin{aligned}
 Q(x, \xi_\omega) &= \text{Min } q_\omega^+ y^+ + q_\omega^- y^- \\
 \text{S.A. } I y^+ - I y^- &= h_\omega - T_\omega x \\
 y^+, y^- &\geq 0
 \end{aligned} \tag{2.6}$$

Neste caso pode-se dizer que para qualquer vetor $h_\omega - T_\omega x$, ou seja, para qualquer solução de x uma solução viável está prontamente disponível e é definida como (Birge e Louveaux, 1997):

$$\begin{aligned}
 h_\omega - T_\omega x, & \text{ se } h_\omega > T_\omega x \\
 T_\omega x - h_\omega, & \text{ se } h_\omega < T_\omega x
 \end{aligned} \tag{2.7}$$

2.8.2

Recurso Fixo

O Recurso Fixo ocorre quando a matriz de recurso W não é afetada pela incerteza.

$$\begin{aligned} Q(x, \xi_\omega) = \text{Min } q_\omega y \\ \text{S.A. } Wy = h_\omega - T_\omega x \\ y \geq 0 \end{aligned} \quad (2.8)$$

2.8.3

Recurso Completo

Afirma-se que um modelo possui recurso completo quando para qualquer solução viável de primeiro estágio o segundo estágio é sempre viável (Birge e Louveaux, 1997).

Considerando a formulação do problema de dois estágios:

$$\begin{aligned} \text{Min}_{x \in X} \left\{ Z(x) = C^T x + E_\xi [Q(x, \xi)] \right\} \\ \text{S.A. } Ax \leq b \\ x \geq 0 \end{aligned} \quad (2.9)$$

Seja $Y(\chi, \omega) = \{y \mid W(\omega)y \geq \chi\}$. Diz-se que $Y(\chi, \omega)$ possui recurso completo se o mesmo é não-vazio para qualquer valor de χ . Fazendo $\chi = h(\omega) - T(\omega)x$, ficamos com:

$$Y(h(\omega) - T(\omega)x, \omega) = \{y \mid W(\omega)y \geq h(\omega) - T(\omega)x\} \quad (2.10)$$

Que expressa a condição de viabilidade do segundo estágio, que deve valer para todo $h(\omega) - T(\omega)x$, que indiretamente, é o mesmo que valer para todo x .

2.8.4

Recurso Relativamente Completo

Exigir recurso completo pode ser infactível em termos práticos, assim, define-se X da seguinte forma:

$$X = \{h_\omega - T_\omega x \mid (\omega, x) \in \Omega \times X\} \quad (2.11)$$

O que na prática significa que não há mais a exigência de viabilidade do primeiro estágio para qualquer valor de x , mas sim, garante-se que dado um x viável o segundo estágio será viável.

2.9

Medidas de comparação entre modelos determinísticos e estocásticos

Em geral, o modelo estocástico apresenta uma complexidade que torna difícil sua resolução. Ribas (2008) afirma que é comum optar pela solução de um modelo determinístico usando a média das variáveis aleatórias ou resolvendo um problema determinístico para cada cenário. No entanto, dois indicadores foram apresentados em Birge e Louveaux (1997), são eles, o Valor da Solução Estocástica (VSS – *Value of Stochastic Solution*) e Valor Esperado da Informação Perfeita (EVPI – *Expected Value of Perfect Information*).

2.9.1

Valor Esperado da Informação Perfeita – EVPI

Ribas (2008) define o EVPI como o indicador que mede o máximo valor que um tomador de decisão estaria disposto a pagar para obter a informação perfeita, isto é, o preço a pagar para conhecer as realizações futuras. Isto supondo que a incerteza seja representada por um número limitado de cenários e ξ a variável aleatória cujas realizações correspondam aos vários cenários.

$$\begin{aligned} \min_{x \in X} (x, \xi) &= C^T x + \min \{q^T y \mid Wy \leq h - Tx, y \geq 0\} \\ \text{S.A. } Ax &\leq b, x \geq 0 \end{aligned} \quad (2.12)$$

Sendo o problema da eq.(2.12) o problema associado a cada cenário ξ , assumase que para cada ξ há pelo menos uma solução viável $x \in \mathfrak{R}^n$. Considere-se que $x^*(\xi)$ seja a solução ótima para a eq.(2.12) e o valor da função objetivo

$z(x^*(\xi), \xi)$ para cada cenário, é possível calcular a solução conhecida como espere-e-veja (*Wait-and-See*, WS). A solução chamada WS corresponde ao valor ótimo do problema quando as realizações futuras de ξ são conhecidas, ou seja, o tomador de decisão pode aguardar e avaliar o futuro antes de decidir. O valor esperado da solução WS é dado por:

$$WS = E_{\xi} \left[\min_x z(x, \xi) \right] = E_{\xi} \left[z(x^*(\xi), \xi) \right] \quad (2.13)$$

Agora se torna possível comparar a solução WS com a solução aqui-e-agora correspondente ao problema de recurso (RP) de dois estágios que pode ser escrito na forma:

$$RP = \min E_{\xi} [z(x, \xi)] \quad (2.14)$$

Sendo solução ótima da eq. (2.14) x^* . A solução RP é definida como aqui-e-agora, pois, a solução de primeiro estágio é definida antes que se conheçam as realizações futuras ξ . Assim, o indicador EVPI é definido como a diferença entre as soluções WS e RP.

$$EVPI = |WS - RP| \quad (2.15)$$

Birge e Louveaux (1997), afirmam que o EVPI mede o valor de saber o futuro com certeza. Esse valor é calculado pela diferença entre o WS, caso em que é possível computar a solução para cada realização calculando o valor esperado dessas soluções e o RP, chamado também de solução “aqui-e-agora” onde conhece apenas a distribuição de probabilidade de ξ . Resumindo, o EVPI significa o quanto o decisor estaria disponível a pagar para obter a informação perfeita.

2.9.2

Valor da Solução Estocástica – VSS

Outra opção ao EVPI é o valor da solução estocástica (*Value of Stochastic Solution* – VSS). Neste caso calcula-se a solução do problema determinístico

associado à média das variáveis aleatórias para comparar com a solução estocástica. Então, define-se o EV (*Expected Value*), como o problema que é obtido ao se substituir as variáveis aleatórias pelo valor esperado (Birge e Louveaux, 1997).

$$EV = \min_x E_{\xi} \left[z(x, \bar{\xi}) \right] \quad (2.16)$$

Sendo $\bar{\xi} = E[\xi]$ e $x^*(\bar{\xi})$ é a solução ótima de EV. Em seguida pode ser definida a solução EEV que é o valor esperado do resultado obtido fixando a solução EV.

$$EV = E_{\xi} \left[z(x^*(\bar{\xi}), \xi) \right] \quad (2.17)$$

Portando, o EEV mede como funciona a solução $x^*(\bar{\xi})$ no problema original com incerteza. O valor VSS, então, é definido como:

$$VSS = |EEV - RP| \quad (2.18)$$

O VSS pode ser interpretado como o benefício esperado por se considerar a incerteza, ou a perda esperada por se optar pela modelagem determinística.

2.10

Modelo de Programação Linear Estocástica de multi-estágios

A incerteza inerente aos dados (e.g. custos, preços, demanda, disponibilidade), junto com a mudança dos dados ao longo do tempo leva naturalmente a uma otimização sequencial sob incertezas. (Casey e Sen, 2005).

Um Programa Linear Estocástico multi-estágio (*multi-stage stochastic linear program*) é um modelo de otimização sequencial estocástica, onde a função objetivo e as restrições são lineares (Casey e Sen, 2005).

De formas distintas, vários autores se utilizam da programação estocástica multi-estágio, Nagar e Jain (2008) utilizam uma abordagem baseada em cenários para endereçar o problema de planejamento de uma cadeia de suprimentos em um ambiente incerto e afirma que o uso da abordagem multi-estágios é capaz de gerar uma economia relevante em problemas desse tipo. Para Sahinidis (2004) apesar de progressos significativos terem sido feitos no que concerne à solução de modelos estocásticos de dois estágios, os modelos multi-estágios ainda permanecem como um desafio significativo. O autor afirma também que modelos multiestágios apresentam um desafio computacional considerável em relação a modelos determinísticos e um entendimento melhor do problema é necessário para a aplicação bem sucedida de algoritmos de solução.

Segundo Casey e Sen (2005), tipicamente, tais modelos se apresentam em duas formas:

- Programas Estocásticos Multiestágio (MSP, *multi-stage stochastic programs*)
- Programas Estocásticos Dinâmicos (SDP, *stochastic dynamics programs* também chamados de Processos de Decisão Markovianos)

Apesar de muitas vezes o SDP ser uma abordagem apropriada para algumas situações, aplicações realísticas exigem uma quantidade muito maior de variáveis do que o SDP pode suportar de forma eficiente. Por este motivo, para aplicações reais de larga escala, com muitas variáveis de estado e restrições, o MSP fornece uma ferramenta de modelagem mais apropriada. No entanto, MSP tem limitações computacionais, como por exemplo, a discretização dos processos estocásticos representando a evolução dos dados aleatórios (Casey e Sen, 2005).

O programa multiestágio com recurso fixo possui a seguinte forma como visto em Birge e Louveaux (1997):

$$\begin{aligned}
 \text{Min}_{x \in X} z &= c^1 x^1 + E_{\xi^2} \left[\min c^2(\omega) x^2(\omega) + \dots + E_{\xi^H} \left[\min c^H(\omega) x^H(\omega) \right] \dots \right] \\
 \text{S.A. } W^1 x^1 &= h^1 \leq b, \\
 T^1(\omega) x^1 + W^2 x^2(\omega^2) &= h^2(\omega), \\
 &\vdots \\
 T^{H-1}(\omega) x^{H-1}(\omega^{H-1}) + W^H x^H(\omega^H) &= h^H(\omega), \\
 x^1 &\geq 0, \\
 x^t(\omega^t) &\geq 0, \\
 t &= 2, \dots, H;
 \end{aligned} \tag{2.19}$$

Onde c é um vetor em \mathfrak{R}^n , h é um vetor em \mathfrak{R}^{m_1} , T é um vetor em \mathfrak{R}^{m-1} , W é uma matriz $m \times n$ e $\xi = (c, h, T, W)$.

2.11

Métodos de Geração de Cenários

Pode-se afirmar que na maioria das aplicações práticas a distribuição dos parâmetros estocásticos deve ser aproximada para distribuições discretas com um número limitado de resultados. A discretização, em geral, é chamada de árvore de cenários ou árvore de eventos (Kaut e Wallace, 2007).

Para Kaut e Wallace (2007), a qualidade da solução de tais modelos depende diretamente da qualidade da árvore de cenários gerada, no entanto, o autor afirma que apesar da variedade de métodos existentes (alguns serão discutidos nesta seção), não há provas de que exista um método de geração de cenários que seja o melhor para todos os modelos existentes, ainda que tais modelos fossem submetidos ao mesmo fenômeno aleatório.

Comparar o desempenho de tais métodos significa comparar seu desempenho prático e não apenas propriedades teóricas. Por exemplo, um método pode aproximar uma distribuição de probabilidade perfeitamente quando o número de saídas tende ao infinito, no entanto, isso não quer dizer que o método é bom para uma geração de poucos cenários, e muitas vezes, não há dados suficientes para um grande número de cenários (Kaut e Wallace, 2007).

Segundo Mitra (2008), ao incorporar pouca incerteza os modelos estocásticos são reduzidos a determinísticos. Por outro lado, incorporar arbitrariamente qualquer incerteza pode levar a soluções irreais ou irrelevantes. Assim os métodos de geração de cenários são de importância central para qualquer modelo de programação estocástica.

Mitra (2008) cita alguns dos métodos possíveis de geração de cenários:

- Estatísticos: são utilizados para determinar uma aproximação discreta (cenários) que melhor se ajuste a distribuição teórica dos dados. O ajuste é feito através dos valores de propriedades estatísticas da distribuição original, como momentos centrais e correlação. Principais métodos: *Moment matching* e *property matching*; Análise das Principais Componentes (PCA); Regressão e suas variantes.

- Amostragem: tem como princípio fundamental tomar uma amostra de uma dada Função Densidade de Probabilidade (FDP) onde os valores selecionados para representar a FDP determinam os cenários e suas respectivas probabilidades. Principais métodos: Monte Carlo, *Bootstrap sampling*, *Markov Chain*, *Monte Carlo sampling*, *Importance sampling*, *Internal sampling*, *Conditional sampling*, *Stratified sampling*.
- Simulação: envolvem a simulação de um processo matemático (por exemplo, Movimento Browniano) onde números aleatórios são introduzidos em sua equação. O resultado fornece realizações da variável aleatória, usados como cenários. Principais métodos: Simulação de Processos Estocásticos, Modelo de Correção de Erros, Vetor Auto-Regressivo (VAR).
- Outros métodos de geração de cenário: Redes neurais, *Clustering*, Redução de cenários, Métodos híbridos.

Keefer (1994) afirma que para aproximar uma distribuição contínua (ou discreta com muitos pontos) por uma distribuição discreta deve-se proceder da seguinte forma:

- Dividir a região onde está definida a distribuição contínua em intervalos,
- Selecionar um ponto que representa cada intervalo,
- Atribuir uma probabilidade a cada ponto.

Esta abordagem é uma solução simples e eficiente no caso de distribuições univariadas. No entanto a maioria dos problemas práticos envolve distribuição multivariada. Alguns autores, como Keefer (1994), tratam o caso de distribuição multivariada assumindo uma destas duas hipóteses:

- As variáveis aleatórias são independentes;
- A distribuição de probabilidade conjunta é conhecida.

Ambas as hipóteses dificilmente são verdadeiras em problemas reais. Em geral, a distribuição de probabilidade conjunta não é conhecida e/ou não se pode assumir independência, pois a correlação entre as variáveis tem efeito importante sobre a geração de cenários (Ribas, 2012).

2.12

Conclusões do capítulo

Neste capítulo foram vistos os principais conceitos que embasam o entendimento, modelagem e resolução do problema da minimização do custo logístico da cadeia de suprimentos.

Primeiramente foi feita uma análise do arcabouço teórico da parte macro de tais problemas onde sua importância é analisada em um contexto mais amplo. Em seguida foi apresentada uma revisão de literatura sobre as principais abordagens utilizadas em tais problemas e como os autores que trabalham nestes problemas lidam com a incerteza. Por fim foi ilustrado o equacionamento matemático das abordagens escolhidas para aplicação nesta dissertação, a abordagem utilizando Modelo de Programação Linear Estocástica de dois, multiestágio e as considerações sobre os tipos de Recurso. Ainda que o tema recurso seja mais importante para problemas resolvidos através de métodos de decomposição, a análise de sua estrutura matemática contribui para o entendimento dos modelos dois e multi estágios.

A apresentação destes conceitos constitui o embasamento teórico necessário para o entendimento do modelo matemático proposto no capítulo 4.

3

Descrição do Problema

3.1

Descrição geral

O problema consiste no planejamento estratégico da cadeia de suprimentos de biodiesel produzido a partir da mamona que é comprada por uma empresa de grande porte produtora de biocombustíveis. Para que tal operação seja viável economicamente, é necessário que haja uma busca constante pela redução de custos. Com vias de reduzir estes custos, faz-se necessário um desenho eficiente da rede logística. Uma solução possível para reduzir tais custos é o posicionamento de entrepostos que consolidam as produções para possibilitar que caminhões maiores façam as entregas na usina esmagadora, evitando, desta forma, que muitos caminhões não consolidados sejam utilizados, o que gera desperdício de capacidade de transporte e aumento do custo logístico total.

3.2

Descrição específica

Posicionar estes entrepostos também consiste em um importante desafio, pois as combinações de localidades possíveis são muitas, tornando-se inviável avaliar todas as alternativas possíveis. Além da questão geográfica, há um impacto no problema devido à própria característica dos entrepostos, que variam quanto à suas capacidades de armazenagem e seus custos.

Há dois tipos de instalações, as bases fixas e os pontos de compra. Bases fixas são instalações perenes e com capacidade maior de armazenagem quando comparados com os pontos de compra. Seu custo de instalação, bem como seus custos operacionais também são maiores, o que se deve ao fato de ser um entreposto de grande porte e ao contrato de uso, que é de maior duração. Os pontos de compra são estruturas mais leves, com menor capacidade de armazenagem, mais baratas e podem eventualmente ser reposicionadas caso os

gestores da operação julguem conveniente. Desta forma, é possível perceber que as decisões consistem em alocar, decidir quais cidades dentre as possíveis candidatas serão usadas como entrepostos, qual o tipo de entreposto instalado, quais serão os fluxos dos produtores até os entrepostos e, finalmente, os fluxos dos entrepostos à usina.

Além destes grandes desafios há outro não menos complexo. Os dados de produção possuem incerteza. Todo o desenho da rede logística deve ser feito com base em dados que são na verdade uma previsão feita por especialistas. Por mais confiável que seja a previsão, criar um modelo matemático de apoio à decisão sem considerar as respectivas incertezas pode resultar em um projeto inadequado da rede logística. Tais incertezas são provenientes, principalmente das incertezas quanto ao regime de chuvas. Como explicado na Seção 2.3 a produção de mamona é dependente da luz solar e das precipitações anuais. A luz solar, historicamente não costuma ser um problema na região estudada, no entanto, as precipitações podem variar consideravelmente de um ano para outro. Assim, caso as produções sejam superestimadas, instalações podem ficar ociosas, gerando altos custos de manutenção para um entreposto com baixo armazenamento. Caso contrário, se as produções fossem subestimadas, os entrepostos não seriam suficientes para armazenar toda a produção e um plano de contingência deveria ser posto em prática, o que acarretaria grandes custos para a rede devido aos grandes deslocamentos. Essas produções são provenientes de pequenos agricultores, no entanto, nesta dissertação o menor nível de agregação considerado foi o município, portanto, é considerada a produção municipal e não por agricultor. Assim, considera-se que um município pode ser produtor, e/ou candidato a receber um entreposto (base fixa ou ponto de compra). Não são todos os municípios que estão disponíveis para receber tais entrepostos, há uma lista predefinida de candidatos que é determinada de acordo com critérios da empresa que podem variar entre a dificuldade de conduzir a infraestrutura (dependendo da acessibilidade da cidade), de decisões da alta gerência devido à razões estratégicas, do fato do município ter um bom histórico produtivo e de se localizar mais centralizado, dentre outros. A Figura 6: apresenta uma ilustração que mostra duas alternativas para a rede logística, na primeira, as pequenas produções são enviadas de forma direta e, na segunda, são enviadas para entrepostos para serem consolidadas e posteriormente encaminhadas à usina.



Figura 6 - Agricultores enviando diretamente suas produções à usina (Parte 1) e Agricultores enviando suas produções aos entrepostos para que sejam consolidadas e enviadas à usina (Parte 2)

No desenho desta rede logística são considerados dois tipos de fluxos. O fluxo de produtos oriundo dos municípios para os entrepostos é definido como fluxo primário. O fluxo de produtos direcionado dos entrepostos para a usina denomina-se fluxo secundário. A Figura 7 ilustra a diferenciação dos fluxos.



Figura 7 - Ilustração dos fluxos. Setas azuis fluxos primários e setas vermelhas fluxos secundários

Logicamente, tal operação incorre em altos custos. Estes custos são divididos em custos de instalação, carregamento e transporte. Os custos de instalação são referentes ao custo de posicionar e manter o entreposto pelo período em que o mesmo estiver instalado. Os custos de carregamento se referem aos custos de carga e descarga do caminhão. Os custos de transporte são os custos de transportar a produção. No fluxo primário estes custos são calculados por ton.km. No fluxo secundário os custos são divididos em faixas de quilometragem

e para cada faixa de quilometragem há um valor específico a ser multiplicado pela quantidade de toneladas transportadas.

O modelo também deve respeitar algumas restrições, primeiramente deve-se garantir que toda a produção seja totalmente escoada até a usina de esmagamento, assim, é natural que deva ser respeitado o balanço dessa produção de cada nó (ou seja, o total de cada tipo de mamona que chega a uma determinada localidade deve ser igual ao total que deixa a mesma localidade). Em cada município só poderá ser instalado um único tipo de entreposto. Um dos principais desafios encontrados pelo modelo na redução de custos é o fato dos agricultores locais serem proibidos de cruzar fronteiras em virtude de questões tributárias. A Figura 8 ilustra um exemplo de como as questões tributárias podem ter influência direta na alocação dos fluxos de produtos da rede logística. A parte “A” da figura indica os produtores entregando suas cargas por fluxo primário, de forma direta na usina que se encontra próxima aos produtores. Na parte “B”, é possível perceber os produtores sendo obrigados a enviar suas cargas para um entreposto (localizado mais distante com relação à usina) e do entreposto as cargas são finalmente enviadas para a usina.




Figura 8 - Questões tributárias gerando dificuldades operacionais

Devem ser respeitadas as capacidades máximas dos entrepostos e só poderá haver fluxo secundário de um dado município para a usina se um entreposto for instalado.

A combinação de tomadas de decisão de fluxos primários e secundários e a instalação de entrepostos compõe o conjunto de decisões que devem ser tomadas para projetar esta rede logística. Cabe lembrar que todas as restrições devem ser consideradas, o que deixaria a tarefa extremamente difícil caso não houvesse o apoio de um modelo matemático. A apresentação da formulação deste modelo é apresentada no capítulo 4.

4

Modelo matemático

Nesta seção é feita a descrição do modelo matemático. Inicialmente é apresentado o modelo dois estágios e posteriormente o modelo multi estágios. Em ambas as seções são apresentados os conjuntos, parâmetros, variáveis, a função objetivo e as restrições do modelo.

4.1

Descrição conceitual do modelo matemático

O modelo matemático desenvolvido para dar suporte ao processo de tomada de decisão é baseado em um PLIM estocástico multiestágio. O problema considerado pode ser classificado como um problema de localização e alocação de fluxos onde grafos orientados são utilizados para representa-lo. Os nós do grafo representam:

- Municípios produtores
- Municípios candidatos a entrepostos
- Usinas

A rede logística deste problema possui dois conjuntos de arcos:

- Fluxos primários
- Fluxos secundários

Tal modelo possui como objetivo minimizar os custos de transporte, de carregamento da mamona e de instalação dos entrepostos. A composição destes custos forma a função objetivo do problema.

São objetos de decisão do modelo a localização e o tipo de entreposto a ser instalado, montantes de fluxos entre os municípios produtores, os entrepostos e os montantes de fluxos entre os entrepostos instalados e as usinas de esmagamento.

Assim, como comentado no capítulo 3, a incerteza impacta diretamente no número de instalações construídas, ou seja, no desenho da rede logística. Para abordar o problema, optou-se por um estudo comparativo entre o modelo dois estágios e o outro com três estágios.

No modelo dois estágios é decidido o posicionamento de instalações no primeiro estágio (que coincide com o período de tempo 0) e no segundo estágio (1º e 2º períodos) são tomadas decisões relativas a alocação de fluxos. Neste modelo as decisões tomadas quanto ao posicionamento de instalações não podem ser modificadas.

No modelo três estágios cada período de tempo coincide com um estágio. No primeiro estágio o modelo decide sobre posicionamento de instalações, enquanto no segundo estágio é decidida a alocação de fluxos com base nas instalações previamente posicionadas, podendo inclusive rever o posicionamento dos pontos de compra. As decisões de alocação de bases fixas não são modificadas. No 3º estágio são tomadas apenas decisões de fluxo. Assim, levando em conta a possibilidade de posicionar um ponto de compra e no período seguinte retirá-lo, pode-se concluir que há maior flexibilidade de decisão no modelo três estágios.

4.2

Descrição conceitual e matemática do Modelo Dois Estágios

Em ambos os modelos trabalha-se com um horizonte de três períodos de tempo, onde cada período corresponde a um ano no qual é planejada a operação de duas safras consecutivas. O período $t=0$ representa um período anterior onde as decisões de alocação antes da colheita são tomadas. Uma vez construídas, tais instalações serão utilizadas na safra seguinte, ou seja, os agricultores no período t se utilizam de instalações construídas no período $t-1$.

O processo decisório associado ao modelo dois estágios é representado pela Figura 9:




Figura 9 - Modelo dois estágios

No modelo dois estágios o primeiro estágio corresponde ao posicionamento das instalações que serão utilizadas em $t=1$ e $t=2$, ou seja, as decisões de instalações são tomadas antes da realização da incerteza. Nos períodos $t=1$ e $t=2$ são usadas as decisões de instalações tomadas em $t=0$, que não podem ser modificadas. Nestes períodos apenas são tomadas decisões de fluxo que são as decisões que encontram a melhor localidade para enviar a produção. Cada linha horizontal representa uma realização possível. Cada realização possui distintos valores de produção, assim como distintas probabilidades.

4.2.1

Conjuntos e subconjuntos

A Tabela 2 lista os conjuntos considerados na formulação do modelo.

Tabela 2 - Conjuntos

<i>Índices e Conjuntos</i>	<i>Descrição</i>
$f \in F$	Faixas de distâncias
$i, j, l \in L$	Municípios
$k \in K$	Tipos de Entrepasto
$p \in P$	Produtos
$t \in T$	Períodos de tempo
$\xi \in \Omega$	Cenários

O índice f representa os custos por faixa de distância, os nós, que representam os municípios produtores, entrepostos ou a usina, são representados pelos índices i, j e l . O fluxo primário representa o fluxo do produtor ao entreposto e o custo é por tonelada multiplicado pela quilometragem percorrida. O índice k representa o tipo de instalação que pode ser um Ponto de Compra ou uma Base Fixa. O índice p representa os dois tipos de produtos existentes, mamona com casca e mamona sem casca. A principal diferença das duas modalidades é quanto ao tempo de germinação. No fluxo secundário o custo é por tonelada de acordo com a faixa de quilometragem. O índice t representa o período de tempo e o índice ξ representa o cenário. A Tabela 3 mostra os subconjuntos utilizados na formulação do modelo.

Tabela 3 - Subconjuntos

<i>Subconjuntos</i>	<i>Descrição</i>
$BF \subset L$	Municípios candidatos à base fixa
$PC \subset L$	Municípios candidatos a pontos de compra
$U \subset L$	Município onde se localiza a usina

4.2.2

Parâmetros

A Tabela 4 mostra os parâmetros utilizados pelo modelo dois estágios:

Tabela 4 - Parâmetros do Modelo Dois Estágios

Parâmetros		Unidade
CC_i	Custo de carregamento	R\$/ton
$CI_{i,k}$	Custo de instalação	R\$
$CMA_{i,k}$	Capacidade máxima do entreposto	ton
COR	Fator de correção do transporte secundário	Adimensional
CTP_p	Custo de transporte primário	R\$/ton.Km
$CTS_{f,p}$	Custo de transporte secundário	R\$/ton
$DI_{i,j}$	Distância entre cidades	Km
LD	Limite de distância	Km
LF_f	Limite de cada faixa	Km
PR^ξ	Probabilidade do cenário	Adimensional
$PRO_{i,p,t}^\xi$	Produção	ton

4.2.3

Variáveis

A Tabela 5 mostra as variáveis utilizadas no modelo

Tabela 17. Variáveis

Variável		Domínio
$xp_{i,j,p,t}^{\xi}$	Quantidade transportada por fluxo primário	\Re^+
$xs_{i,j,p,t}^{\xi}$	Quantidade transportada por fluxo secundário	\Re^+
$in_{i,k,t}$	Entrepasto instalado	$\{0,1\}$
Variável auxiliar		Domínio
$inl_{i,k,t}$	Variável auxiliar de instalação	$\{0,1\}$

A variável auxiliar $inl_{i,k,t}$ serve para que os custos de instalação sejam cobrados apenas no período em que a instalação é posicionada. Maior detalhamento sobre esta variável é dado na seção 4.2.4.

Para o modelo dois estágios, temos a $in_{i,k,t}$ como variável que é decidida no primeiro estágio e se mantém para o segundo sem alterações. As variáveis $xp_{i,j,p,t}^{\xi}$ (fluxo primário) e $xs_{i,j,p,t}^{\xi}$ (fluxo secundário) são variáveis de segundo estágio e existem somente nos períodos $t=1$ e $t=2$.

4.2.4

Função objetivo

A função objetivo consiste no somatório dos custos que se deseja minimizar. Neste caso em especial é composta por três parcelas, relativas aos custos de carregar os caminhões, ao custo de instalar um entreposto e o custo de transporte. Neste modelo os custos de instalação são custos de primeiro estágio, enquanto os custos de transporte e carregamento são custos de segundo estágio.

A eq.(4.1) representa a função objetivo composta pelos custos de instalação, (eq.(4.4)) (4.4), carregamento (eq.(4.2)) e transporte (eq.(4.3)). Nos custos de instalação a diferença $in_{i,k,t} - inl_{i,k,t}$ representa a modelagem utilizada para garantir que a rede só incorra no custo de instalação no período exato em que o entreposto for instalado. As restrições representadas na eq. (4.9) e na eq.(4.10) garantem que isso ocorra. Na eq.(4.3) o parâmetro COR indica um fator de correção. Tal fator é colocado, pois, na usina, o descarregamento não faz parte da composição de custos da empresa analisada nesta dissertação, pagando, assim, apenas os custos de carregamento efetuado nos entrepostos.

$$\min_{xp, xs \in \mathfrak{R}^+, in, inl \in \{0,1\}} Z = pin + ptr + pca \quad (4.1)$$

$$pin = \sum_{i,k,t} CI_{i,k} (in_{i,k,t} - inl_{i,k,t}) \quad (4.2)$$

$$ptr = \sum_{i,j,p,\xi,f,t} PR_{\xi} DI_{i,j} CTP_p xp_{i,j,p,t}^{\xi} + \sum_{i,j,p,\xi,f,t} PR_{\xi} DI_{i,j} CTS_{f,p} xs_{i,j,p,t}^{\xi} \quad (4.3)$$

$$pca = \sum_{i,j,p,\xi,t} PR_{\xi} CC_i xp_{i,j,p,t}^{\xi} + COR \sum_{i,j,p,\xi,t} PR_{\xi} CC_i xs_{i,j,p,t}^{\xi} \quad (4.4)$$

4.3.5

Restrições

Nesta seção é apresentado o equacionamento das restrições. A explicação sobre as restrições são seguidas de seus respectivos equacionamentos.

A eq.(4.5) limita que apenas um tipo de entreposto possa ser instalado em um determinado município, ou seja, não poderão ser simultaneamente instalados um ponto de compra e uma base fixa.

$$\sum_k in_{i,k,t} \leq 1 \quad \forall i \in L, \forall t \in T \quad (4.5)$$

A eq.(4.6) diz que deve ser respeitada a capacidade máxima de cada entreposto. Esta equação também é a responsável por informar ao modelo que

toda a capacidade de armazenagem disponível depende da instalação de um entreposto no período anterior.

$$\sum_{j,p} xs_{i,j,p,t}^{\xi} \leq \sum_k CMA_{i,k} in_{i,k,t-1} \quad \forall i, j \in L, \forall t \in T, \forall \xi \in \Omega \quad (4.6)$$

A eq.(4.7) é uma restrição de balanço de fluxo que diz que a produção total transportada até os entrepostos deve ser igual à produção total dos produtores, ou seja, o total transportado por fluxo primário mais o total transportado por fluxo secundário deve ser exatamente igual ao total produzido pelos produtores de cada município.

$$\sum_{i| i \notin U} PRO_{i,p,t}^{\xi} = \sum_{i,u,p,\xi,t} (xp_{i,u,p,t}^{\xi} + xs_{i,u,p,t}^{\xi}) \\ \forall p \in P, \quad \forall t \in (T - \{0\}), \quad \forall \xi \in \Omega \quad (4.7)$$

A eq.(4.8) diz que os fluxos dos produtores aos entrepostos somados à produção dos municípios que funcionam também como entrepostos devem ser iguais ao somatório dos fluxos de produtos enviados para a usina.

$$\sum_i (xp_{i,j,p,t}^{\xi} + xs_{i,j,p,t}^{\xi}) + PRO_{j,p,t}^{\xi} = \sum_l (xp_{j,l,p,t}^{\xi} + xs_{j,l,p,t}^{\xi}) \\ \forall i, j, l \in L, \forall p \in P, \forall \xi \in \Omega \quad (4.8)$$

A eq.(4.9) diz respeito ao valor da variável auxiliar $inl_{i,t,k}$ para os pontos de compra. Para as bases fixas, esta variável tem valor zero no período em que a instalação foi posicionada e tem valor 1 em todos os outros períodos. Desta forma o modelo só incorre em custos de instalação no período exato que foi colocado o entreposto. Para os pontos de compra esta variável vale sempre 0, pois, o ponto de compra é instalado período a período.

$$inl_{i,t,k \in PC} = 0 \quad \forall i \in L, \quad \forall t \in T \quad (4.9)$$

A eq.(4.10) também se refere a variável $inl_{i,t,k}$ e diz que ela deve ter o mesmo valor da variável $in_{i,t,k}$ posicionada no período $t-1$. Esta restrição faz com que os custos de instalação sejam cobrados apenas no período em que o entreposto é de fato instalado.

$$inl_{i,t,k \in BF} = in_{i,t-1,k \in BF} \quad \forall i \in L, \quad \forall t \in T \quad \forall k \in K \quad (4.10)$$

A eq. (4.11) serve para fixar as decisões de instalações tomadas no primeiro período para os outros períodos posteriores, ou seja, as decisões sobre instalações de entrepostos tomadas em um período $t-1$ são mantidas obrigatoriamente no período t .

$$in_{i,k,t} \geq in_{i,k,t-1} \quad \forall i \in L, \quad \forall t \in T, \quad \forall k \in K \quad (4.10)$$

4.3

Descrição conceitual e matemática do Modelo Três Estágios

A Figura 10 mostra o processo decisório representado pelo modelo três estágios.




Figura 10 - Modelo Três Estágios

No modelo três estágios o primeiro estágio corresponde ao posicionamento das instalações que serão utilizadas em $t=1$ e $t=2$, ou seja, as decisões de instalações são tomadas antes da realização da incerteza do período $t=1$. Nos

períodos $t=1$ e $t=2$ são usadas as decisões de instalações tomadas em $t=0$. Para o modelo três estágios há a possibilidade de rever as decisões tomadas quanto ao posicionamento dos pontos de compra, ou seja, um ponto de compra instalado em $t=0$ pode ser desinstalado em $t=1$, após observação da realização da incerteza referente à primeira safra. Inputar ao modelo flexibilidade permite a revisão dos pontos de compra segundo o incremento de informação disponível após a realização de parte da incerteza. As decisões de instalação de bases fixas continuam sem poder ser alteradas. Nos período $t=2$ e $t=3$ são tomadas decisões de fluxo que são as decisões que encontram a melhor localidade para enviar a produção.

4.3.1

Conjuntos e subconjuntos

A Tabela 6 lista os conjuntos utilizados. Cabe ressaltar que são os mesmos à exceção do conjunto T .

Tabela 6 - Conjuntos

<i>Índices e Conjuntos</i>	<i>Descrição</i>
$f \in F$	Faixas de distâncias
$i, j, l \in L$	Municípios
$k \in K$	Tipos de Entrepasto
$p \in P$	Produtos
$\xi \in \Omega$	Cenários

A explicação para a não utilização do conjunto T encontra-se mais detalhada na seção 4.3.2.

4.3.2

Parâmetros

Todos os parâmetros utilizados são os mesmos vistos na Tabela 7 à exceção da produção que agora não recebe o índice t e o parâmetro PE_{ξ} . Este parâmetro é o responsável pela relação de precedência entre os cenários, fazendo o papel do índice t do modelo OE2E.

4.3.3

Variáveis

A Tabela 7 mostra as variáveis utilizadas no modelo

Tabela 7 - Variáveis

	Variável	Domínio
$xp_{i,j,p}^{\xi}$	Quantidade transportada por fluxo primário	\Re^{+}
$xs_{i,j,p}^{\xi}$	Quantidade transportada por fluxo secundário	\Re^{+}
$in_{i,k}^{\xi}$	Entrepósito instalado	$\{0,1\}$
	Variável auxiliar	Domínio
$inl_{i,k}^{\xi}$	Variável auxiliar de instalação	$\{0,1\}$

Para o modelo três estágios a variável $in_{i,k \in PC}^{\xi}$ considerada é a de primeiro e de segundo estágio. Neste caso, o modelo pode optar por rever uma decisão de ponto de compra tomada no primeiro estágio. A variável $in_{i,k \in BF}^{\xi}$ é uma variável decidida no primeiro estágio e se mantém ao longo do segundo e do terceiro estágios. As variáveis $xp_{i,j,p}^{\xi}$ e $xs_{i,j,p}^{\xi}$ são consideradas variáveis de segundo e terceiro estágios.

4.3.4

Função objetivo

A função objetivo consiste no somatório dos custos que se deseja minimizar. Neste caso é composta por três parcelas, relativas aos custos de carregar os caminhões, ao custo de instalar um entreposto e ao custo de transporte. Os custos de instalação, neste modelo, são de primeiro e segundo estágios. Os custos de transporte são de segundo e terceiro estágios assim como os custos de carregamento.

A eq.(4.12) representa a função objetivo composta pelos custos de instalação eq.(4.13), transporte eq. (4.14) e carregamento eq. (4.15). Assim como no modelo dois estágios, nos custos de instalação a diferença $in_{i,k}^{\xi} - inl_{i,k}^{\xi}$ representa a modelagem utilizada para garantir que a rede só incorra no custo de instalação no período exato em que o entreposto for instalado. As restrições (4.21) e (4.22) garantem que isso ocorra. Cabe ressaltar, que agora a parcela dos custos de instalação eq.(4.13) é multiplicada pela probabilidade. Isto ocorre pois agora a probabilidade da realização da incerteza do estágio posterior influi na decisão de instalação.

$$\min_{xp, xs \in \mathbb{R}^+, in, inl \in \{0,1\}} Z = pin + ptr + pca \quad (4.11)$$

$$pin = \sum_{i,k,\xi} PR^{\xi} CI_{i,k} (in_{i,k}^{\xi} - inl_{i,k}^{\xi}) \quad (4.12)$$

$$ptr = \sum_{i,j,p,\xi,f} PR^{\xi} DI_{i,j} CTP_{f,p} xp_{i,j,p}^{\xi} + \sum_{i,j,p,\xi,f} PR^{\xi} DI_{i,j} CTS_{f,p} xs_{i,j,p}^{\xi} \quad (4.13)$$

$$pca = \sum_{i,j,p,\xi} PR^{\xi} CC_i xp_{i,j,p}^{\xi} + COR \sum_{i,j,p,\xi} PR^{\xi} CC_i xs_{i,j,p}^{\xi} \quad (4.14)$$

4.3.5

Restrições

Conceitualmente as restrições são muito parecidas. A eq.(4.16) limita que apenas um tipo de entreposto possa ser instalado em um determinado município, a eq.(4.17) diz respeito à capacidade de armazenagem do entreposto e condiciona o transporte secundário à sua abertura, a eq.(4.18) é uma restrição de balanço de fluxo que diz que a produção total transportada até os entrepostos deve ser igual à produção total dos produtores, a eq.(4.19) é a equação de balanço entre as produções e a usina, a eq.(4.20) diz respeito ao valor da variável auxiliar $inl_{i,k}^\xi$ para os pontos de compra.

$$\sum_k inl_{i,k}^\xi \leq 1 \quad \forall i \in L, \forall \xi \in \Omega \quad (4.15)$$

$$\sum_{j,p} xs_{i,j,p}^\xi \leq \sum_k CMA_{i,k} inl_{i,k}^{PE_\xi} \quad \forall i, j \in L, \forall \xi \in \Omega, \forall p \in P \quad (4.16)$$

$$\sum_i (xp_{i,j,p}^\xi + xs_{i,j,p}^\xi) + PRO_{j,p}^\xi = \sum_l (xp_{i,j,p}^\xi + xs_{i,j,p}^\xi) \quad (4.17)$$

$$\forall i, j, l \in L, \quad \forall p \in P, \forall \xi \in \Omega$$

$$\sum_{i|j \notin usinas} PRO_{i,p}^\xi = \sum_{i,u,\xi} (xp_{i,u,p}^\xi + xs_{i,u,p}^\xi) \quad \forall p \in P, \quad \forall \xi \in (\Omega - \{0\}) \quad (4.18)$$

$$Inl_{i,k \in PC}^\xi = 0 \quad (4.19)$$

$$\forall i \in L, \quad \forall t \in T, \quad \forall \xi \in \Omega$$

A eq.(4.21) é análoga à eq.(4.9), contudo, utiliza como índice o parâmetro PE_ξ para indicar as realizações.

$$inl_{i,k \in BF}^\xi = inl_{i,k \in BF}^{PE_\xi} \quad \forall i \in L, \quad \forall \xi \in \Omega \quad (4.20)$$

A eq.(4.22) é análoga à eq.(4.10) com uma pequena diferença, pois a decisão de instalação que não pode ser revista é a relativa à base fixa.

$$inl_{i,k \in BF}^\xi \geq inl_{i,k \in BF}^{PE_\xi} \quad \forall i \in L, \quad \forall \xi \in \Omega \quad (4.21)$$

Cabe ressaltar que as eq.(4.21) e (4.22) são as restrições chamadas de restrições de não-antecipatividade, que são restrições que garantem que as decisões sejam tomadas antes da realização das correspondentes incertezas.

5

Estudo de caso

Nesta seção são apresentados os dados de entrada, a geração de cenários e os resultados obtidos após a otimização.

5.1

Dados de entrada

O modelo foi construído utilizando o software AIMMS, que consiste em uma plataforma para desenvolvimento de modelos matemáticos utilizando linguagem própria. Além disso, foi criado um banco de dados em Microsoft Access, que é responsável pelo armazenamento dos parâmetros do modelo matemático, bem como dos resultados obtidos após a otimização.

Cabe ressaltar que o posicionamento geográfico (coordenadas) de cada nó (municípios) reflete as coordenadas reais. As distâncias utilizadas também são distâncias reais entre municípios considerando a utilização de rodovias.

A Tabela 8 mostra os nós do modelo.

Tabela 8 - Nós do modelo

Elementos	Total
Municípios	145
Usinas	1
Candidatos a Pontos de Compra	26
Candidatos a Bases Fixa	9

Objetivando manter o sigilo da empresa, alguns dados são apresentados sob a forma de proporções, multiplicados por uma constante arbitrária. Na Tabela 9, os custos de carregamento são multiplicados pela constante κ .

Tabela 9 - Custos de carregamento

Tipo de Fluxo	Custo de carregamento (κR\$/ton)
Primário	2
Secundário	1

A Tabela 10 mostra os custos de transporte por quilometragem organizada por faixas de quilometragem. Aqui também os dados reais serão preservados, o que é mostrado é uma proporção tomando como base o custo utilizando a constante σ . Cabe lembrar que o fluxo primário é o fluxo entre os pequenos produtores e os entrepostos, e que o fluxo secundário é aquele entre tais entrepostos e as usinas de esmagamento.

Tabela 10 - Custos de transporte

Tipo de Transporte	Faixa de Custo	Custo de transporte (σ R\$)
Primário	única (custo por quilômetro)	1
Secundário	1 (0-100km)	13,6
Secundário	2 (100-200km)	21,7
Secundário	3 (200-300km)	29,9
Secundário	4 (300-500km)	35,9
Secundário	5 (500-1000km)	77,2
Secundário	6 (1000-1500km)	127,7

O custo do transporte primário é calculado por ton.km, como mostrado na Tabela 10. Cabe ressaltar que os dados reais estão multiplicados pela constante μ , para preservar os dados originais. Os demais custos referentes ao transporte secundário são calculados por tonelada em cada faixa específica presente na mesma tabela.

A Tabela 11 mostra as estimativas iniciais da quantidade produzida por cada estado e o total produzido.

Tabela 11 - Estimativas de produção por estado

Estado	Produção (μ ton.)
BA	748,70
CE	2.235,79
BA	545,65
PB	112,41
PE	796,71
PI	85,91
RN	111,72
Total	4.636,89

A Tabela 12 mostra as capacidades de armazenamento dos dois tipos de instalação disponíveis.

Tabela 12 - Capacidades das instalações

Instalação	Capacidade (ton)
Ponto de Compra	4500
Bases Fixas	7500

Na Tabela 13 são mostrados os custos de instalação dos entrepostos.

Tabela 13 - Custos de instalação

Instalação	Custos (R\$)
Ponto de Compra	80000
Bases Fixas	100000

5.2

Geração de cenários

Nesta seção é discutido como foram gerados os cenários usados na otimização estocástica do Modelo de Otimização Estocástica Dois Estágios (OE2E) e do Modelo Três Estágios (OE3E).

Os cenários foram gerados baseando-se nos dados disponíveis acerca da produção nacional de mamona. Na Figura 11 é mostrada a série histórica.




Figura 11 - Dados de produção de mamona no Brasil. Fonte: CONAB (2012)

Um dos principais desafios na geração dos cenários para a produção foi a pouca disponibilidade de dados. Outra dificuldade foi a não existência de histórico da produção específica de cada município utilizado no estudo.

Foi, portanto, considerado que os desvios percentuais da produção nacional representam os desvios da produção para os municípios considerados no estudo. Assim, foram plotados os desvios percentuais na Figura 12. Nota-se que há 35 períodos (primeiro período é a diferença entre 76/77 e 78/79; segundo período é a diferença entre 80/81 e 82/83 e assim por diante).




Figura 12 - Desvios percentuais da produção

Para evitar a alta complexidade computacional e dada a pouca quantidade de dados, optou-se por utilizar um método de discretização que fosse capaz de selecionar três pontos suficientemente bons para representar a distribuição dos desvios percentuais. Assim sendo, o próximo passo foi plotar um histograma com a distribuição acumulada como mostra a Figura 13:




Figura 13 - Histograma dos desvios percentuais

As categorias foram definidas a partir de intervalos percentuais de mesmo tamanho, exceção feita às categorias extremas.

Keefer e Bodily (1983) propuseram uma extensão do método *Swanson-Megill* sugerindo que fosse aproximado por uma PMF chamando então de *Extended Swanson-Megill* onde os percentis 10, 50 e 90 seriam ponderados pelas probabilidades 0,3; 0,4 e 0,3 e é recomendada para aproximar a distribuição lognormal, ainda que não deva ser usada em lognormais com assimetrias muito altas. Os autores ainda afirmam que o método pode ser usado em outras distribuições além da lognormal. Este método foi considerado o mais adequado encontrado na literatura para a discretização, tendo em vista os dados disponíveis.

Esses desvios percentuais são então selecionados de forma apropriada para compor os cenários gerados pelos métodos de discretização. Foram usados os percentis 10%, 50% e 90% o que respectivamente resultam nos valores -59,38%; -2,78% e 104,39% com as probabilidades 0,3; 0,4 e 0,3.

5.3

Resultados - Modelo determinístico (EV)

O modelo possui 2.368 restrições, 4.187 variáveis sendo que 105 do tipo binário (inteira). O tempo de resolução foi em torno de cinco segundos. O solver utilizado foi o CPLEX 12.5.

Nesta seção foi efetuado o cálculo considerando o problema determinístico, conforme definido na seção 2.9.2.

Como exemplos das soluções encontradas para este modelo, podem ser visualizados fluxos e entrepostos mostrados pela Figura 14.

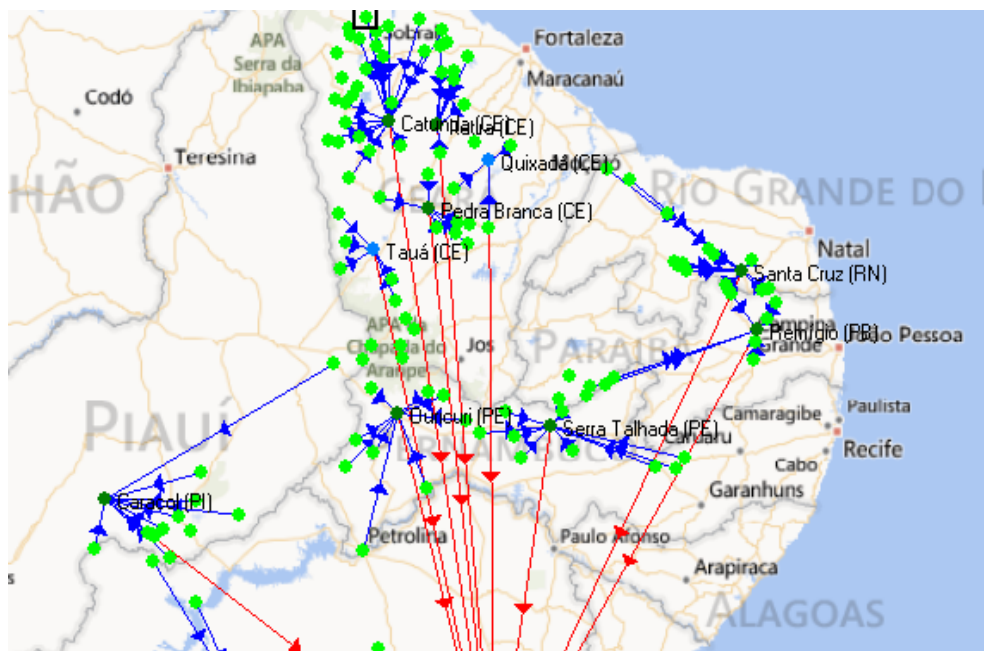


Figura 14 - Fluxos e entrepostos para modelo determinístico

A Função Objetivo (F.O.) encontrada para este problema foi de R\$8.426.782,84. Na Tabela 14 são listados todos os entrepostos instalados após a otimização do problema.

Tabela 14 - Entrepósitos selecionados após a otimização

Cidade	Instalação	Período	
		0	1
Caracol (PI)	Ponto de Compra	1	1
Catunda (CE)	Ponto de Compra	1	1
Itatira (CE)	Ponto de Compra	1	1
Matias Cardoso (MG)	Base Fixa	1	1
Nova Redenção (BA)	Base Fixa	1	1
Ouricuri (PE)	Ponto de Compra	1	1
Pedra Branca (CE)	Ponto de Compra	1	1
Porteirinha (MG)	Ponto de Compra	1	1
Quixadá (CE)	Base Fixa	1	1
Remígio (PB)	Ponto de Compra	1	1
Santa Cruz (RN)	Ponto de Compra	1	1
São Francisco (MG)	Base Fixa	1	1
Serra do Ramalho (BA)	Base Fixa	1	1
Serra Talhada (PE)	Ponto de Compra	1	1
Tauá (CE)	Base Fixa	1	1
Irecê (BA)	Base Fixa	1	1

Cabe observar que, para este modelo, todas as instalações são posicionadas no período $t=0$.

5.4

Resultados - Modelo OE2E

O modelo matemático OE2E gerado possui um total de 5.488 restrições e 28.204 variáveis, das quais 105 são do tipo binário (inteira). O tempo de solução é de cerca de 5 segundos. O solver utilizado foi o CPLEX 12.5.

A Figura 15 mostra o processo da criação da árvore de cenários para um município qualquer.

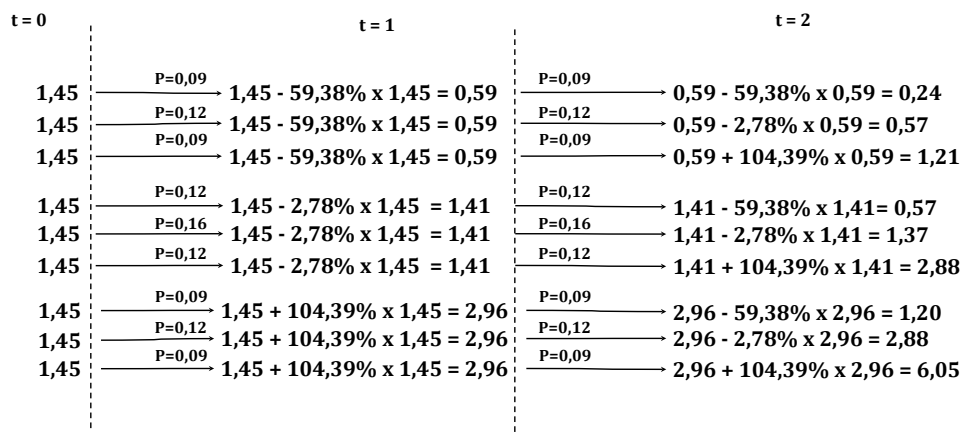


Figura 15 - Árvore de cenários para modelo OE2E

O principal propósito da construção do Modelo OE2E é levar em conta as incertezas na produção e encontrar uma solução razoavelmente boa para todos os cenários. Para este problema o valor da Função Objetivo é R\$ 8.550.761,55.

A diferença entre os modelos determinístico e OE2E consiste no fato do município de Independência (CE) que entregava sua produção em Pedra Branca (CE) torna-se um ponto de compra, fazendo com que os fluxos da região se organizassem de forma distinta.

5.5

Qualidade da solução do modelo OE2E

Esta seção faz a análise da qualidade das soluções encontradas pelo modelo OE2E. O primeiro indicador calculado é o VSS (*Value of Stochastic Solution*) que representa o valor da solução estocástica. O cálculo é feito tomando a diferença em módulo entre o EEV (valor esperado do resultado obtido fixando a solução EV) e o RP (que é o Problema de recurso do modelo OE2E).

O modelo determinístico leva em conta o valor esperado da produção. A função objetivo encontrada foi R\$ R\$ 8.556.309,01.

Assim, pode-se calcular o Valor da Solução Estocástica (VSS) que consiste na diferença entre o EEV (R\$ 8.556.309,01) e o RP (R\$ 8.550.761,55), sendo este último o valor da F.O. Relativa ao *Recourse Problem* do modelo OE2E:

$$VSS = EEV - RP = R\$ 5.547,46 \quad (5.1)$$

Pode-se dizer então, que R\$ 5.547,46, representando 0,06% do EEV, é a economia que o tomador de decisão teria ao incorporar as incertezas ao modelo. Em termos de instalações, significa no período $t=1$ posicionar um entreposto na cidade de Independência (CE), o que faz com que a rede tenha que modificar diversos fluxos na região. Cabe ressaltar que o valor é pequeno, mas, para cada árvore de cenários esse valor se modifica.

Outro indicador importante é o EVPI, definido formalmente na seção 2.9.1, que significa quanto o tomador de decisão estaria disposto a pagar pela informação perfeita. Para este cálculo é necessário o prévio resultado do WS, Espere-e-veja, que na prática significa supor que seria possível calcular a otimização tendo a certeza absoluta da ocorrência um cenário de produção específico. A função objetivo é calculada para cada cenário, e ao final é calculado o valor esperado do WS de cada cenário. Tendo em posse o RP (R\$ 8.550.761,55) e o WS (R\$ 8.455.365,14), torna-se possível calcular o Valor Esperado da Informação perfeita:

$$EVPI = RP - WS = R\$ 95.396,41 \quad (5.2)$$

Nota-se que o valor que o tomador de decisão estaria disposto a pagar pela informação perfeita é 1,12% do RP.

5.6

Resultados - Modelo OE3E

O modelo matemático três estágios gerado possui um total de 4.529 restrições e 19.246 variáveis, das quais 513 são do tipo binário (inteira). O tempo de solução é de cerca de 10 segundos.

A Figura 16 mostra o processo da criação da árvore de cenários tomando como exemplo um município genérico.

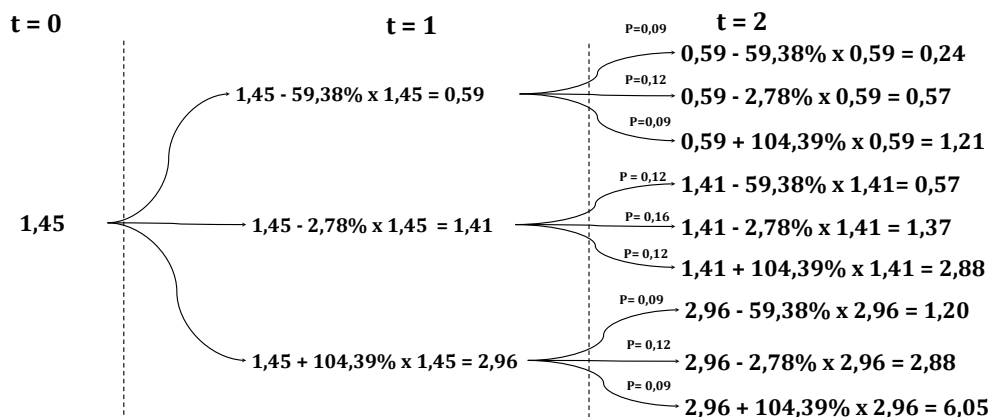


Figura 16 - Exemplo do cálculo da árvore de cenários para o modelo OE3E

O primeiro resultado a ser ressaltado é a função objetivo com valor R\$ 7.700.019,00. A diferença entre as funções objetivo do modelo OE2E e OE3E representa o ganho em termos de economia de custos que se obtém por adicionar flexibilidade à rede. Tal flexibilidade significa a possibilidade que o modelo OE3E tem de desinstalar pontos de compra. Assim, pode-se definir um indicador Ganho por Adicionar Flexibilidade (GAF) que seja a diferença entre OE2E e OE3E:

$$GAF = OE2E - OE3E = \text{R\$ } 850.742,55 \quad (5.3)$$

Lembrando que a F.O. do OE2E vale R\$ 8.550.761,55, ou seja, uma diferença que percentualmente corresponde a 9,95% do OE2E. Esses valores podem ser definidos como o ganho que se obtém ao incluir flexibilidade nas decisões da rede logística.

Para o modelo OE3E as instalações posicionadas encontram-se na Tabela 15.

Tabela 15 - Comparativo de entrepostos entre modelos OE3E e OE2E.

OE3E				OE2E	
Cidade	Instalação	Período e Cenários			Período
		t=0	t=1		t=0 t=1
		0	1	2	3
Boa Viagem (CE)	Ponto de Compra				1
Caracol (PI)	Ponto de Compra	1	1	1	1
Catunda (CE)	Ponto de Compra	1	1	1	1
Independência (CE)	Ponto de Compra	1		1	1
Itatira (CE)	Ponto de Compra	1	1	1	1
Juru (PB)	Ponto de Compra	1		1	1
Matias Cardoso (MG)	Base Fixa	1	1	1	1
Mombaça (CE)	Ponto de Compra	1		1	1
Mossoró (RN)	Ponto de Compra				1
Nova Redenção (BA)	Base Fixa	1	1	1	1
Ouricuri (PE)	Ponto de Compra	1	1	1	1
Pedra Branca (CE)	Ponto de Compra	1	1	1	1
Pilão Arcado (BA)	Ponto de Compra	1		1	1
Porteirinha (MG)	Ponto de Compra	1	1	1	1
Quixadá (CE)	Base Fixa	1	1	1	1
Remígio (PB)	Ponto de Compra	1	1	1	1
Santa Cruz (RN)	Ponto de Compra	1	1	1	1
São Francisco (MG)	Ponto de Compra			1	1
Serra do Ramalho (BA)	Base Fixa	1	1	1	1
Serra Talhada (PE)	Ponto de Compra	1	1	1	1
Tamboril (CE)	Ponto de Compra				1
Tauá (CE)	Base Fixa	1	1	1	1
Irecê (BA)	Base Fixa	1	1	1	1
OE3E	Total Pontos de Compra	13	9	14	17
	Total Bases Fixas	6	6	6	6
OE2E	Total Pontos de Compra				11
	Total Bases Fixas				6

Pela Tabela 15 é possível notar que o modelo OE2E, devido à sua menor flexibilidade é mais conservador na colocação de entrepostos. Por exemplo, no modelo OE3E o entreposto de Juru (PB) é instalado no período 0 e desinstalado no cenário 1 do período 1. O mesmo não acontece no modelo OE2E onde uma instalação posicionada não pode ser modificada.

Mapas, fluxos e análises complementares desta rede logística encontram-se na seção 8 (Apêndice).

5.7

Conclusões do capítulo

A principal conclusão deste capítulo, tendo em vista os resultados de ambos os modelos, é de que o modelo três estágios possui os menores custos devido a grande diferença de flexibilidade de instalação dos pontos de compra.

Como mostrado na Tabela 15, no período $c=1$ são instalados 15 entrepostos, no período $c=2$, 20 entrepostos e no período $c=3$, 23 entrepostos. Desta forma, o fato de o modelo poder adaptar a quantidade de entrepostos conforme a produção aumenta ou diminui mostra a importância da flexibilidade de decisão proporcionada pelo modelo OE3E. Neste sentido, o modelo OE3E oferece um ganho considerável no que diz respeito ao planejamento de longo prazo, o que não ocorre no modelo OE2E, que possui uma solução de instalação de entrepostos que não pode ser modificada independente da variação das safras. A flexibilidade também é importante para evitar que instalações construídas fiquem ociosas por um excesso de capacidade da rede logística ou, até mesmo que instalações emergenciais precisem ser obtidas no caso da capacidade da rede ser insuficiente.

A Tabela 16 mostra um resumo das funções objetivo e indicadores calculados.

Tabela 16 - Funções Objetivo e indicadores

Modelo	F.O.	Indicador	Valor	Dif %	Valor
EEV	R\$ 8.556.309,01	VSS	R\$ 5.547,46	VSS/EEV	0,06%
WS	R\$ 8.455.365,14	EVPI	R\$ 95.396,41	EVPI/OE2E	1,12%
OE2E	R\$ 8.550.761,55	GAF	R\$ 850.742,55	GAF/OE2E	9,95%
OE3E	R\$ 7.700.019,00				

O fato de o EVPI ser apenas 1,12% do modelo OE2E significa que para a árvore de cenários considerada no problema, há pouca diferença entre o modelo espere-e-veja (informação perfeita) e o problema de recurso. Para o VSS, representando 0,06% do EEV, pode-se concluir que na abordagem OE2E há pouco ganho em considerar incerteza neste problema.

Conclusões e Estudos futuros

A dissertação buscou trazer uma metodologia que contribuísse na modelagem e solução do problema de planejamento de redes, mais especificamente, da rede logística de produção de biodiesel através da mamona. Para atingir esse objetivo, foi estruturada uma revisão bibliográfica onde se procurou identificar as técnicas utilizadas para modelar e resolver problemas de planejamento de redes. Tendo em vista que o problema visava à minimização dos custos logísticos totais, pode-se afirmar que a modelagem matemática, mais especificamente a Pesquisa Operacional, consiste em uma abordagem adequada para solucionar o problema.

Assim, considerando as técnicas disponíveis na literatura da Pesquisa Operacional, buscou-se, mais especificamente, abordar uma questão crucial no planejamento da rede logística estudada, que é o tratamento das incertezas na produção da safra. Tais incertezas possuem várias causas, podendo ser destacada a variação de pluviosidade como a principal. Visando à construção de um modelo onde houvesse a possibilidade de incorporação de incertezas ao problema de otimização dos custos da cadeia de suprimentos de biodiesel produzido através da mamona, foram consideradas duas abordagens distintas. As abordagens utilizadas consistem no desenvolvimento de dois modelos de programação estocástica, o modelo de otimização estocástica Dois Estágios (OE2E) e o modelo de otimização estocástica Três Estágios (OE3E). Os modelos propostos têm como principal objetivo posicionar entrepostos e alocar fluxos de produtos de forma a obter o menor custo possível. Neste sentido, é fundamental a incorporação da incerteza, que torna o modelo mais aderente à realidade enfrentada pela empresa estudada neste trabalho.

Para gerar os cenários foi utilizado o método de discretização *Extended Swanson-Megil* (ESM). O desempenho do modelo de programação estocástica depende diretamente da árvore de cenários gerados para representar a incerteza. No caso específico do problema estudado, não havia a disponibilidade de uma

quantidade suficientemente grande de dados que permitisse saber qual a distribuição de probabilidade das safras de mamona.

O modelo OE2E apresenta uma quantidade reduzida de entrepostos instalados. Isso ocorre, ele se protege de uma possível não viabilidade de períodos posteriores antecipando instalações. No modelo OE3E já há um quantitativo maior de instalações posicionadas, principalmente de pontos de compra. Esse resultado é lógico, pois, a cada período é dado ao modelo matemático a possibilidade de rever o posicionamento de Pontos de Compra, o que faz com que o modelo possa instalar um grande número e futuramente desinstalar caso seja conveniente.

6.1

Contribuições da dissertação

Nesta seção são destacadas as principais contribuições que esta dissertação tem a oferecer para o estado-da-arte assim como para o estado-da-prática.

Uma revisão de literatura que oferece uma gama de possibilidades e abordagens para que quem precisar lidar com este tipo de problema possua um arcabouço teórico no assunto, e assim, possa começar a pesquisar a melhor solução para seu problema específico.

O desenvolvimento de dois modelos matemáticos, um de Dois Estágios e outro de Três Estágios. Ambos fornecem uma maneira de lidar com as incertezas. Ressalta-se que o modelo Três Estágios fornece mais flexibilidade, pois há possibilidade de rever decisões tomadas previamente, no entanto, se o número de cenários por estágio começar a crescer muito, os recursos computacionais necessários crescerão em uma proporção ainda maior.

O Estudo ajuda a resolver um problema que interessa para o Brasil como um todo. Cada vez mais a busca por combustíveis menos poluentes será uma tônica da indústria energética e o biodiesel constitui uma alternativa importante. Neste sentido, conseguir estruturar uma parte da cadeia de suprimentos de uma das matérias – primas utilizadas na produção do biodiesel constitui em um ganho de eficiência para a produção deste combustível, o que pode aumentar a margem de lucro da cadeia como todo.

O trabalho tem ainda, uma contribuição no campo da Responsabilidade Social, tendo em vista que ajuda a empresa em questão a lograr êxito no projeto

de compra da produção de pequenos agricultores, reduzindo o custo logístico de uma operação que muitas vezes possui pouca escala de transporte. Por este motivo o posicionamento estratégico de entrepostos para ajudar a consolidar esta produção constitui em uma importante solução.

6.2

Perspectivas de trabalhos futuros

Esta seção tem como objetivo endereçar alguns assuntos que constituem uma continuidade do estudo proposto ao longo desta dissertação.

O trabalho propõe a construção de dois modelos, Dois e Três estágios. Uma questão interessante é avaliar se há algum ganho com a colocação de um quarto estágio. Quais os ganhos poderiam ser obtidos caso a empresa já pudesse planejar os custos por quatro ou mais safras seria algo importante a ser avaliado. Outra investigação pertinente seria o ganho de precisão obtido no modelo ao se aumentar o número de cenários. Ao aumentar a árvore de cenários, pode-se representar de forma mais precisa a distribuição de probabilidades. No entanto, seria necessário um grande esforço de levantamento de dados históricos das produções municipais para que o estudo fosse mais preciso.

Quanto aos métodos de geração de cenários, outros poderiam ser testados e uma avaliação das diferenças de soluções obtidas ao se implementar diferentes métodos.

Outras abordagens para lidar com a incerteza, como por exemplo, a Programação Robusta e a Programação *Fuzzy* podem ser testadas e comparadas.

Referências bibliográficas

ALVES, M.O.; SOBRINHO, J.N.; CARVALHO, J.M.M. **Possibilidades da mamona como fonte de matéria-prima para a produção de biodiesel no nordeste brasileiro**. Documentos do ETENE, Banco do Nordeste do Brasil. Disponível em:

<<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/52372/1/LV-Possibilidades-da-mamona.pdf>> Acesso em 15/07/2013>. Acesso em: 15 jun. 2004.

ANP, **Agência Nacional de Petróleo**. Disponível em: <<http://www.anp.gov.br/>>. Acesso em 15 jun. 2013.

AZVARADEL, A.C. **A contribuição da política estadual para viabilizar a participação da agricultura familiar no programa nacional da produção e uso do biodiesel: o caso da Bahia**. (D.Sc.) Dissertação – Universidade Federal do Rio de Janeiro. Rio de Janeiro. 2008.

BALLOU, R.H. **Gerenciamento da Cadeia de Suprimentos/Logística Empresarial**. Porto Alegre: Bookman, 2006.

BEALE, E. On Minizing A Convex Function Subject to Linear Inequalities. **Journal of the Royal Statistical Society. Series B (Methodological)**, v.17, n.2, p. 173-184. 1955.

BIODIESELBR, disponível em:

<<http://www.biodieselbr.com/biodiesel/economia/selo-combustivel-social.htm>>

Acesso em 15 jul. 2013.

BIRGE, J.R.; LOUVEAUX, F. **Introduction to Stochastic Programming**. Springer Series in Operations Research, New York: Springer-Verlag. 1997.

CANEL, C.; DAS, S.R. Modeling global facility location decisions: integrating marketing and manufacturing decisions. **Industrial Management & Data Systems**. v. 102 n. 2, p.110 – 118. 2002.

CASEY, M.S.; SEN, S. The Scenario Generation Algorithm for Multistage Stochastic Linear Programming. **Mathematics of Operations Research** v.99 n.9 p.999-999. 2005.

CHAUDHRY, S.S.; CHOI, I.; SMITH, D.K. Facility location with and without maximum distance constraints through the median problem. **International Journal of Operations & Production Management**. Vol. 15 n.10, p.75 – 81. 1995.

CHARNES, A.; COOPER, W. Chance-constrained programming. **Management Science**. v. 6, n.1, p.73-79. 1959.

CHOTIPANICH, S. Positioning facility management. **Facilities**, v. 22 n.13/14 p. 364-372. 2004.

CONAB, **Companhia Nacional de Abastecimento**, disponível em: <<http://www.conab.gov.br/>>. Acesso em 10 jul 2013.

COTTS, D. **The Facility Management Handbook**, 2nd ed., New York: AMACOM. 1999.

DANTZIG, G. Linear Programming Under Uncertainty. **Management Science**. v.50, n.12 Supplement, p.1764-1769, 1955.

DIEESE, **Estatísticas do meio rural**, disponível em: <<http://www.dieese.org.br/anuario/2008/estatisticasMeioRural2008.pdf>>. Acesso em 5 jul. 2013.

EAI, disponível em: <http://www.eai.in/ref/ae/bio/tf/biomass_tf.html> Acesso em 15 jul. 2013.

EMBRAPA, 2007. disponível em: <<http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Mamona/SistemaProducaoMamona/torta.htm>> Acesso em 15 jul. 2013.

FALASCA, M.; ZOBEL, C.W. A two-stage procurement model for humanitarian relief supply chains. **Journal of Humanitarian Logistics and Supply Chain Management**, v. 1 n. 2, p.151 – 169, 2011.

FERREIRA, L.; BORENSTEIN, D. Análise da viabilidade da produção de biodiesel a partir da soja no Brasil. In: **XXXIX Simpósio Brasileiro de Pesquisa Operacional**. 2007, Fortaleza, CE.

FLEURY, P.F.; WANKE, P.; FIGUEIREDO, K.F. **Logística empresarial: a perspectiva brasileira**. São Paulo: Editora Atlas, 2000.

GALBRAITH, J.R. Organization Design: An Information Processing View. **Army organization effectiveness journal**, v. 8, n. 1, p. 425-69, 1969.

HAAS, M.J.; MCALOON, A.J.; YEE, W.C.; FOGLIA, T.A. A process model to estimate biodiesel production costs. **Bioresource technology**, v. 97, n. 4, p. 671-678, 2006.

HAKIMI, S.L. Optimum locations of switching centers and the absolute centers and medians of a graph. **Operations Research** v.12, n. 3, p.450-459, 1965.

HIGLE, J. Stochastic Programming: Optimization When Uncertainty Matters, **Tutorials in operations research New Orleans Chapter 1**. 2005.

HOFFMAN, J.; SCHNIEDERJANS, M. A two-stage model for structuring global facility site selection decisions. **International Journal of Operations & Production Management**, v. 14, n. 4, p. 79-96, 1994.

JAYARAMAN, V. An efficient heuristic procedure for practical-sized capacitated warehouse design and management. **Decision Sciences Journal**, v.29, n.3 p. 729–745, 1998.

KAUT M.; WALLACE, S.W. Evaluation of scenario generation methods for stochastic programming. **Pacific Journal of Optimization**, v.3, n.2, p.257-271, 2007.

KAVEH, A.; SHARAFI, P. Ant colony optimization for finding medians of weighted graphs. **Engineering Computations: International Journal for Computer-Aided Engineering and Software**, v.25, n.2, p. 131-138, 2008.

KEEFER, D.L.; BODILY, S.E. Three-point Approximations for Continuous Random Variables. **Management Science**, v.29, n.5, p.595-609, 1983.

KEEFER, D.L. Certainty Equivalents for Three-point Discrete-distribution Approximations. **Management Science**, v.40, n.6, p.760-773, 1994.

KÖRBITZ, W. Biodiesel production in Europe and North America, an encouraging prospect. **Renewable Energy**, v. 16, n.1, p. 1078-1083, 1999.

LACERDA, L. Armazenagem estratégica: analisando novos conceitos. In: FLEURY, P.; WANKE, P.E.; FIGUEIREDO, K. **Logística empresarial: a perspectiva brasileira**. São Paulo: Atlas, 2000, p. 154-160.

LEÃO, R.R.C.C. **Otimização da cadeia de biodiesel baseada na agricultura familiar**. Rio de Janeiro, RJ. 2009. (M.Sc.) Dissertação – Pontifícia Universidade Católica do Rio de Janeiro.

LEÃO, R.R.C.C.; HAMACHER, S.; OLIVEIRA, F. Optimization of biodiesel supply chains based on small farmers: A case study in Brazil. **Bioresource Technology**, v. 102, n. 19, p. 8958-8963. 2011.

LEE, W. The role of support services and FM in the introduction of change management. In: REUVID, J.; HINKS, J. **Managing Business Support Services**. 2nd ed, London, UK: Kogan page Ltd publisher, 2002.

LEDUC, S.; NATARAJAN, K.; DOTZAUER, E.; MCCALLUM, I.; OBERSTEINER, M. Optimizing biodiesel production in India. **Applied Energy**, v. 86, n. Suppl. 1, p. S125-S131. 2009.

LEIRAS, A. **Optimization under Uncertainty for Integrated Tactical and Operational Planning of the Oil Supply Chain**. Rio de Janeiro, RJ, 2011. (D.Sc.). Tese – Pontifícia Universidade Católica do Rio de Janeiro, 2011.

MIRANDA, J.; G.; CAMARGO, S.R.; PINTO, L.R.; CONCEIÇÃO, S.V. FERREIRA, R.P.M. Hub location under hub congestion and demand uncertainty: the brazilian case study. **Brazilian Operations Research Society**, v.31, n.2, p. 319-349. 2011.

MITRA, S. Scenario generation for stochastic programming. **Optirisk Systems: White papers series**, UK, 2008. Disponível em <<http://www.optirisk-systems.com/papers/opt004.pdf>>. Acesso em: 15 jul. 2013.

MSANGI, S.; EVANS, M. Biofuels and developing economies: Is the timing right? **Agricultural Economics**, V. 44, n. 4-5, p. 501-510. 2013.

NAGAR, L.; JAIN, K. Supply chain planning using multi-stage stochastic programming. **Supply Chain Management: An International Journal**, v.13, n.3, p.251–256. 2008.

NUTT, B. The essence and value of facility management. In: **(Proceedings) Facility Management**. 2002, Seminar, Chulalongkorn University, Bangkok.

OLIVEIRA, F.; LEÃO, R.; HAMACHER, S. A robust approach for the biodiesel supply chain based on small farmers. In: **XLII SBPO: Simpósio Brasileiro de Pesquisa Operacional**. Bento Gonçalves, RS. 2010.

OLIVEIRA, F.; HAMACHER, S. A simulation-based approach to the optimization of the petroleum product supply chain under uncertainty: a case study in northern Brazil. **Industrial & Engineering Chemistry Research**, v.51, n.11, p 4279–4287, 2012.

PINEDO, K.S.; ABREU, Y.V. Determinação de pontos ótimos para localização e implantação de usinas de biodiesel no estado do Tocantins. **Revista Produção Online**. v.11, n. 4, p. 1160-1181 disponível em: <<http://producaoonline.org.br/rpo/article/view/828/849>>. 2011. Acesso em 13 jul. 2013.

PNPB, **Programa Nacional de Produção de Biodiesel** disponível em <<http://portal.mda.gov.br/portal/saf/programas/biodiesel/2286217>>. Acesso em 5 jul. 2013.

PRAÇA, E.R.; COUTINHO, E.J.R.; PRATA, B.A.; FREITAS, L.A.A. Localização otimizada de plantas de produção de biodiesel de mamona no estado do Ceará: Um modelo baseado em programação linear. In: **3º Congresso Brasileiro de P&D em Petróleo e Gás**. 2004, Salvador, BA. Disponível em: <http://www.portalabpg.org.br/PDPetro/3/trabalhos/IBP0205_05.pdf>. Acesso em 5 jul. 2013.

PRAÇA, E.R. **Distribuição de gás natural no Brasil: um enfoque crítico e de minimização de custos**. Fortaleza, CE, 2003. (M.Sc.) Dissertação - Universidade Federal do Ceará.

RIBAS, G.P. **Modelo de Programação Estocástica para o Planejamento Estratégico da Cadeia Integrada de Petróleo**. Rio de Janeiro, RJ, 2008. (M.Sc.) Dissertação - Pontifícia Universidade Católica do Rio de Janeiro.

RIBAS, G.P. **Planejamento Operacional de Refinarias de Petróleo sob Incerteza**. Rio de Janeiro, RJ. 2012. (D.Sc.) Tese - Pontifícia Universidade Católica do Rio de Janeiro.

SAHINIDIS, N. Optimization under uncertainty: state-of-the-art and opportunities. **Computers and Chemical Engineering**, v.28, n. 6-7, p.971-983. 2004.

SENADO BRASILEIRO, disponível em:

<<http://legis.senado.gov.br/legislacao/ListaTextoIntegral.action?id=227880>>.

Acesso em 15 jul. 2013.

SERPA, F.G.; HAMACHER, S. Modelo de programação matemática para suporte à decisão na compra e distribuição de dutos e umbilicais. In: **XLI SBPO: Simpósio Brasileiro de Pesquisa Operacional**, 2012, Rio de Janeiro, RJ.

SHAPIRO, A.; PHILPOTT, A. A Tutorial on Stochastic Programming, 2007. Disponível em: < <http://stoprog.org/stoprog/SPTutorial/SPTutorial.php>>. Acesso em 15 jul. 2013.

SOTOFT, L.F.; RONG, B.; CHRISTENSEN, K.V.; NORDDAHL, B. Process simulation and economical evaluation of enzymatic biodiesel production plant. **Bioresource technology**, v. 101, n. 14, p. 5266-5274, 2010.

SOUZA, A.S.; TÁVORA, F.J.A. F. Antecipação de plantio e irrigação suplementar na mamoneira. I – Efeito nos componentes de produção. In: **Congresso Brasileiro de Mamona**, 2006, Aracajú, SE.

VAN DYNE, D.L.; WEBER, J.A.; BRASCHLER, C.H. Macroeconomic effects of a community-based biodiesel production system. **Bioresource Technology**, v. 56, p. 1-6, 1996.

VIEIRA, J.N.S. A agroenergia e os novos desafios para a política agrícola no Brasil. In: **O futuro da indústria: Biodiesel**, 2006, Brasília, DF. Disponível em: <http://www.desenvolvimento.gov.br/arquivos/dwnl_1201279825.pdf>. Acesso em 15 jul. 2013.

WANKE, P. Uma Revisão dos Programas de Resposta Rápida: ECR, CRP, VMI, CPFR, JIT II, 2004. Disponível em: <http://www.ilos.com.br/web/index.php?option=com_content&view=category&layout=blog&id=4&Itemid=279&lang=br&limitstart=70>. Acesso em 15 jul. 2013.

WANKE, P.F.; ZINN, W. Strategic logistics decision making. **International Journal of Physical Distribution & Logistics Management**, v. 34 n. 6, p. 466-78. 2004.

WEISS, E.A. **Oilseed Crops**. Londres, UK, Longman, 1983.

YANG, J.; LEE, H. An AHP decision model for facility location selection, **Facilities**, v. 15 n. 9/10, p. 241 – 254, 1997.

ZHANG, Y.; DUBE, M.A.; MCLEAN, D.D.; KATES, M. Biodiesel production waste from cooking oil. **Bioresource technology**, v. 89, n.1, p. 1-16, 2003.

ZHANG, M.; HUANG, J.; ZHU, J. Reliable facility location problem considering facility failure scenarios. **Kybernetes**, v. 41, n.10, p.1440 -1461, 2012.

Apêndice

As Figuras 18 e 19 mostram os entrepostos instalados nos cenários: 1, 2 e 3. Os entrepostos instalados no cenário 1 serão utilizados pelos fluxos de 1.1, 1.2 e 1.3; os entrepostos instalados no cenário 2 serão utilizados pelos fluxos de 2.1, 2.2 e 2.3 e os entrepostos instalados no cenário 3 serão utilizados pelos fluxos de 3.1, 3.2 e 3.3. Para exemplificar, as Figuras 17, 18 e 19 mostram os entrepostos instalados em 1, 2 e 3 com os fluxos respectivamente de 1.1, 2.1 e 3.1.

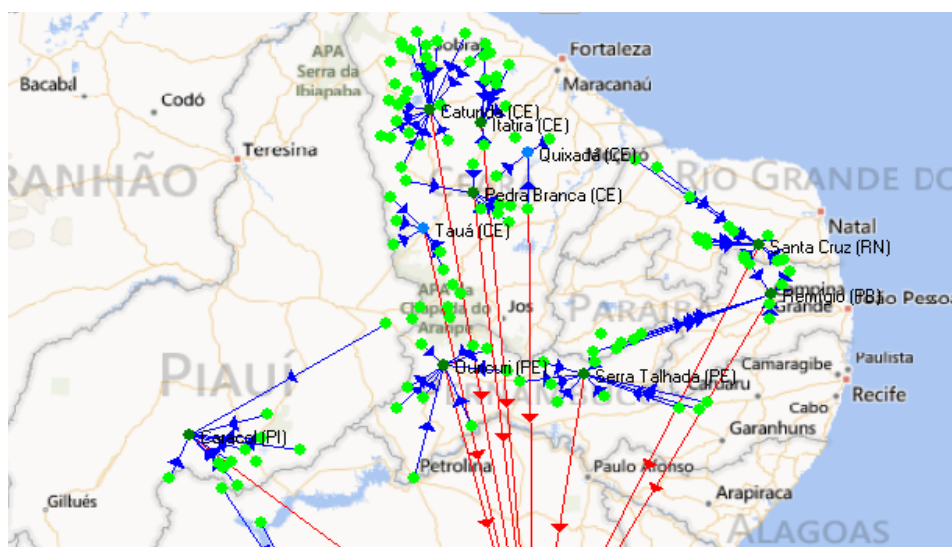


Figura 17 - Rede logística - Cenários 1; 1.1 – PI, RN, PB, PE e CE

Na Figura 17 é possível visualizar no resultado da otimização o problema relatado pela Figura 8. Tomando como exemplo o estado da Paraíba, cidades como Pedra Branca e Manaíra, no extremo sul do estado, entregam suas produções em Remígio, pois não podem cruzar a fronteira e entregar em Serra Talhada (PE). Apesar de não ser objetivo do trabalho aprofundar essa questão, cabe comentar que esta rota pouco eficiente ocorre por questões tributárias. Tais questões obrigam os pequenos produtores a fazerem suas entregas primeiramente dentro do estado para que as cargas posteriormente sejam consolidadas, notas fiscais sejam emitidas e, então, possam cruzar a fronteira.

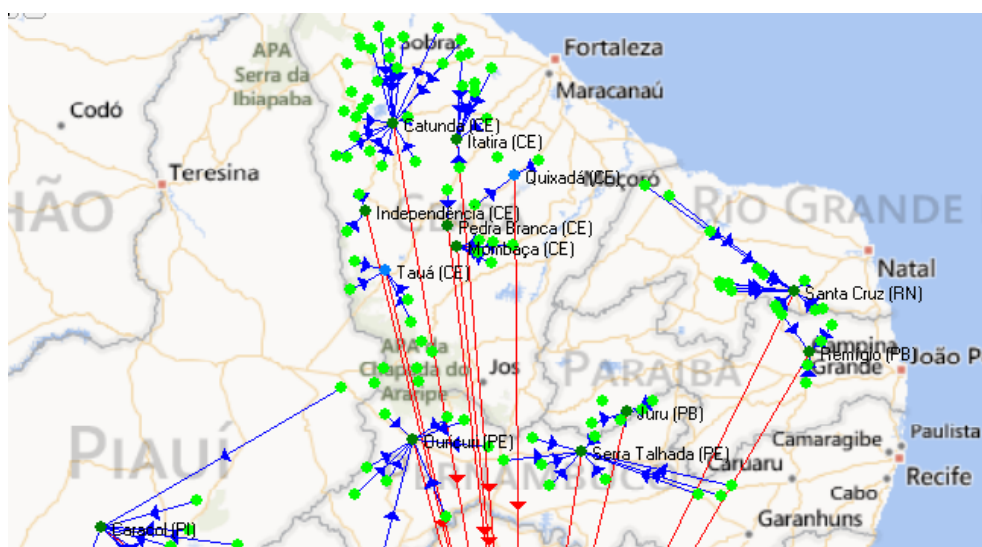


Figura 18 - Rede logística - Cenários 2; 2.1 – PI, RN, PB, PE e CE

Na Figura 18 é possível notar algumas diferenças na rede. No estado do Ceará, os entrepostos de Independência e Mombaça são instalados. No estado da Paraíba, agora há o entreposto localizado em Juru, que torna mais lógico o desenho da rede.

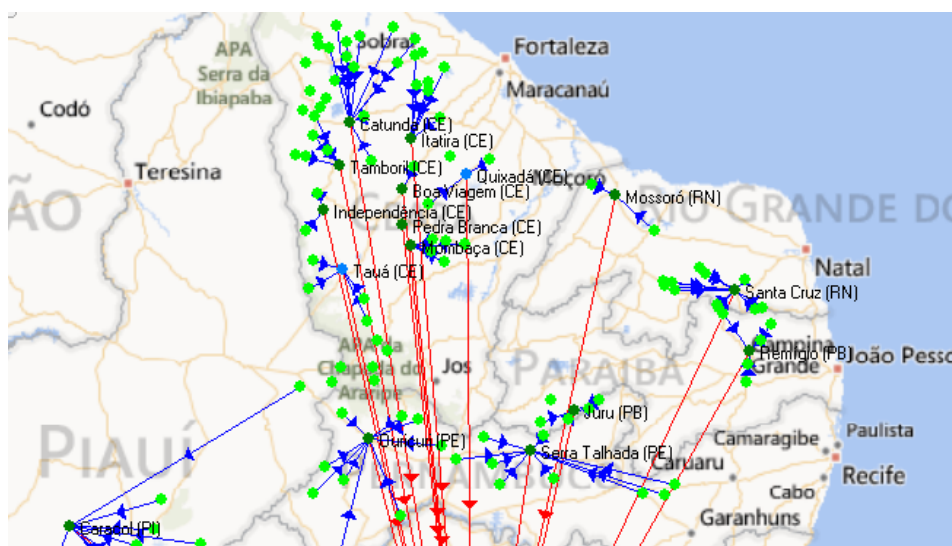


Figura 19 - Rede logística - Cenários 3; 3.1 – PI, RN, PB, PE e CE

Na Figura 19, agora há a instalação dos Pontos de Compra de Tamboril e Boa Viagem. No Rio Grande do Norte é instalado o Ponto de Compra de Mossoró.

As Figuras 20, 21 e 22 retratam a rede logística para os estados da Bahia e Minas Gerais.

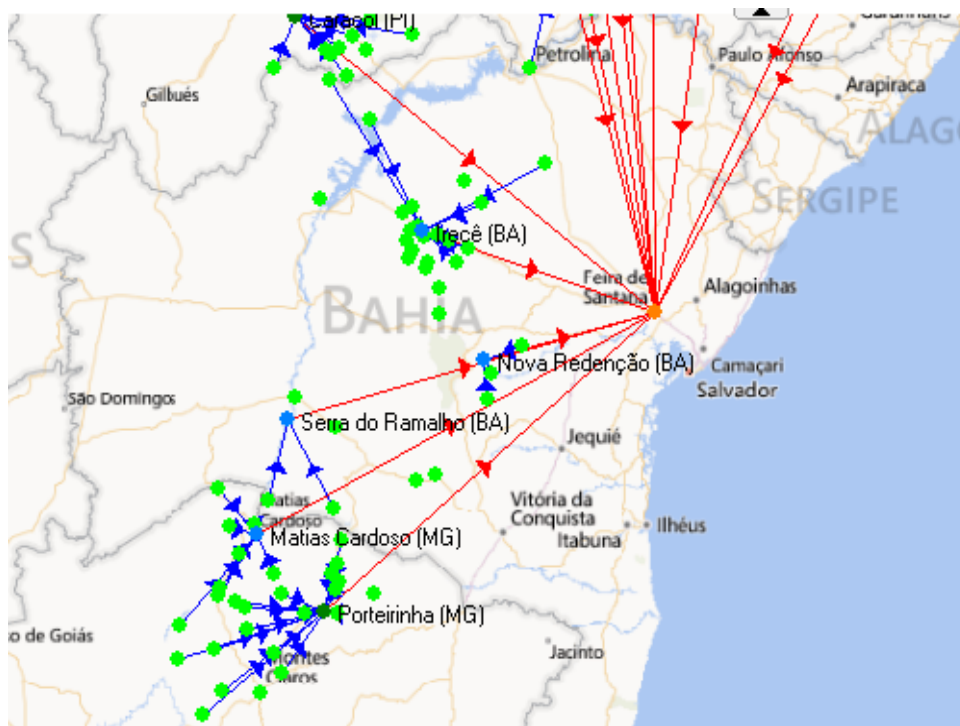


Figura 20 - Rede logística - Ramo 1; 1.1 - BA e MG

A Figura 20 também evidencia o problema mostrado na Figura 8. As cidades de Malhada (BA) e São Sebastião Laranjeiras (BA) em vez de entregar suas produções em Matias Cardoso (MG) devem percorrer uma distância maior para entregar em Serra do Ramalho (BA).

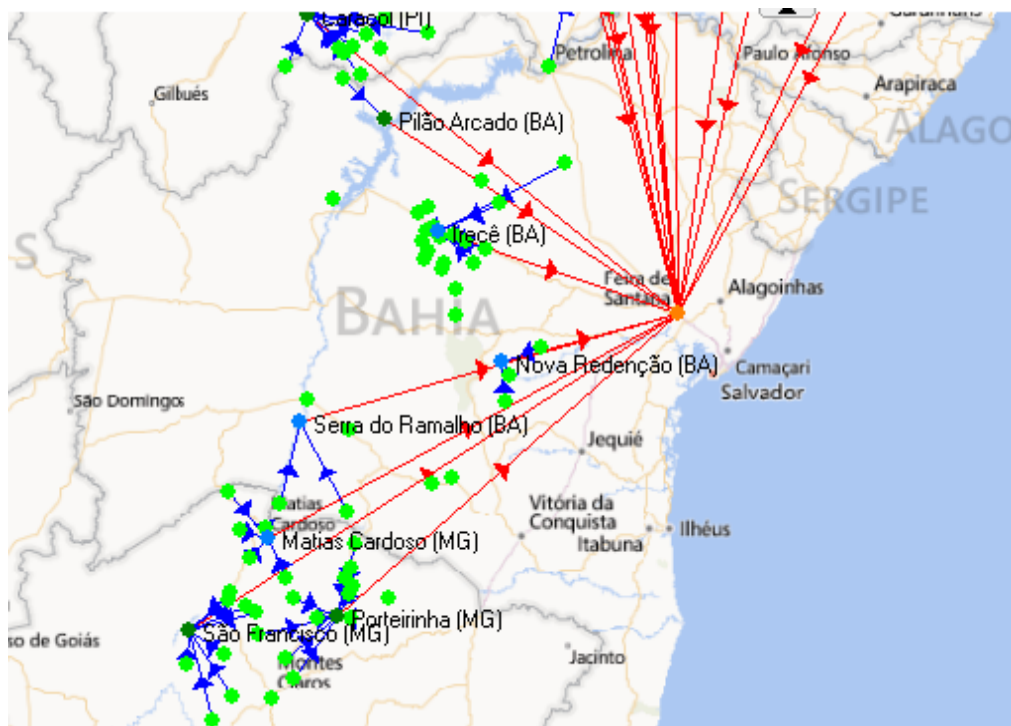


Figura 21 - Rede logística - Ramo 2; 2.1 - BA e MG

Com o acréscimo de produção, é possível visualizar na Figura 21 que um novo ponto de compra foi instalado em Pilão Arcado (BA) e outro em São Francisco (MG).

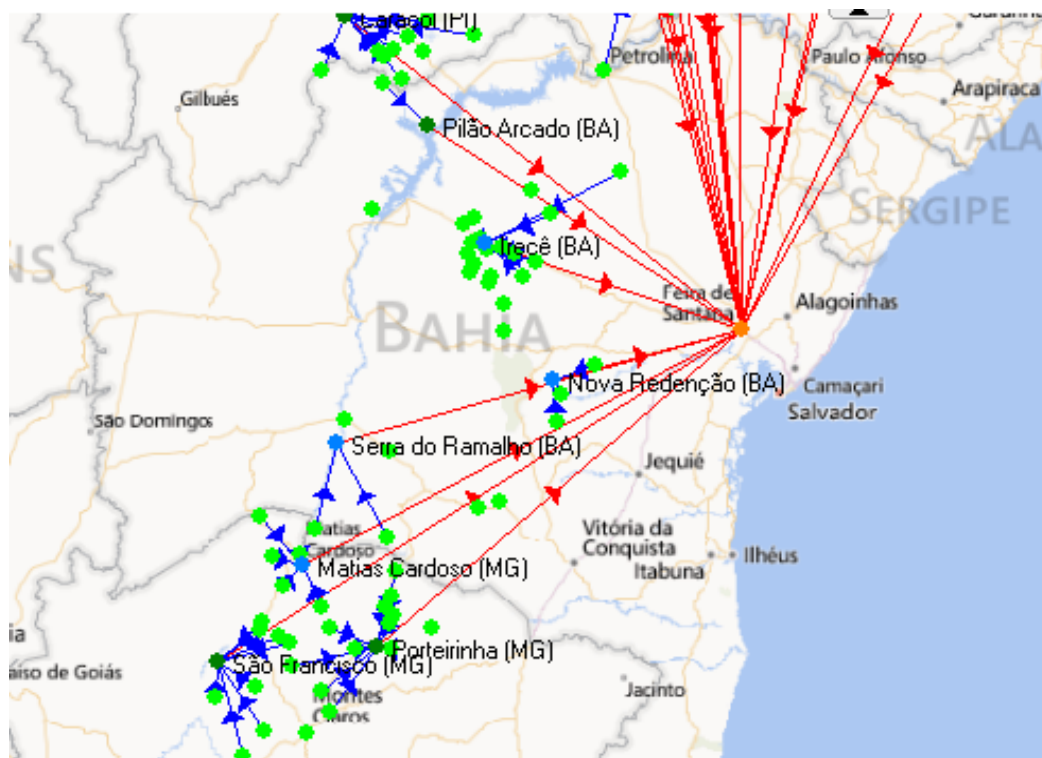


Figura 22 - Rede logística - Ramo 3; 3.1 - BA e MG

Na Figura 22 não há mudanças de configuração na rede, ainda que o fluxo de produtos tenha se intensificado, não são configuradas mudanças de sentido nos fluxos.