

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

**DIMENSIONAMENTO E SEQÜENCIAMENTO DE LOTES DE
PRODUÇÃO NA INDÚSTRIA DE SUPLEMENTOS PARA
NUTRIÇÃO ANIMAL**

Eli Angela Vitor Toso

São Carlos
2008

**DIMENSIONAMENTO E SEQÜENCIAMENTO DE LOTES DE
PRODUÇÃO NA INDÚSTRIA DE SUPLEMENTOS PARA
NUTRIÇÃO ANIMAL**

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

**DIMENSIONAMENTO E SEQÜENCIAMENTO DE LOTES DE
PRODUÇÃO NA INDÚSTRIA DE SUPLEMENTOS PARA
NUTRIÇÃO ANIMAL**

Eli Angela Vitor Toso

Tese apresentada ao Programa de Pós-graduação em Engenharia de Produção da Universidade Federal de São Carlos como parte dos requisitos para a obtenção do título de Doutor em Engenharia de Produção.

Orientador: Prof. Dr. Reinaldo Morabito
Co-orientador: Prof. Dr. Alistair R. Clark

SÃO CARLOS
2008

**Ficha catalográfica elaborada pelo DePT da
Biblioteca Comunitária/UFSCar**

T714ds

Toso, Eli Angela Vitor.

Dimensionamento e seqüenciamento de lotes de produção na indústria de suplementos para nutrição animal / Eli Angela Vitor Toso. -- São Carlos : UFSCar, 2008.
191 f.

Tese (Doutorado) -- Universidade Federal de São Carlos, 2008.

1. Dimensionamento de lotes. 2. Sequenciamento da produção. 3. Indústria de nutrição animal. 4. Heurística. I. Título.

CDD: 658.53 (20^a)



FOLHA DE APROVAÇÃO

Aluno(a): Eli Angela Vitor Toso

TESE DE DOUTORADO DEFENDIDA E APROVADA EM 03/04/2008 PELA
COMISSÃO JULGADORA:

Prof. Dr. Reinaldo Morabito Neto
Orientador(a) PPGE/UFSCar

Prof. Dr. Alistair Richard Clark
CEMS/UWE

Profª Drª Vitória Maria Miranda Pureza
PPGE/UFSCar

Prof. Dr. Marcos Nereu Arenales
ICMC/USP

Profª Drª Débora Pretti Ronconi
POLI/USP

Prof. Dr. Geraldo Robson Mateus
DCC/UFMG

Prof. Dr. Mário Otávio Batalha
Coordenador do PPGE/UFSCar

Ao meu marido Milton e aos meus

filhos Luiz e João.

AGRADECIMENTOS

Ao meu orientador Reinaldo Morabito por toda orientação, apoio, incentivo, compreensão e pelo admirável exemplo de postura profissional.

Ao meu co-orientador Alistair Clark pela orientação e comprometimento desde o início até o final deste trabalho.

A professora Vitória Pureza pela ajuda e incentivadora confiança.

Aos membros da banca de exame de qualificação e de defesa, pela revisão cuidadosa e construtiva.

Ao Programa de Pós-Graduação do Departamento de Engenharia de Produção da UFSCar e a secretária Raquel, sempre disposta a ajudar. A todos do laboratório de Modelagem, especialmente a Deisemara, por toda ajuda e amizade.

Ao CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico – pelo apoio financeiro através de bolsa de doutorado e de doutorado ‘sanduíche’.

A todos os funcionários da empresa estudada, especialmente Luiz Traldi, Marcelo, Fernanda, Raquel e Castor.

A todos os meus familiares e amigos pela compreensão nos muitos momentos de ausência que este trabalho exigiu.

Ao meu marido Milton, que sempre me apoiou em todas as decisões. Obrigada pelos sonhos compartilhados, pelo amor, respeito e compreensão irrestritos.

Aos meus filhos, Luiz e João, por toda alegria e beleza em minha vida. O amor de vocês me mantém.

RESUMO

Este trabalho estuda o problema integrado de dimensionamento e seqüenciamento de lotes de produção na indústria de suplementos para nutrição animal. O problema de dimensionamento de lotes nesta indústria consiste em determinar o que e quanto produzir em cada período, minimizando os custos de estocagem e horas extras. O problema de seqüenciamento de lotes consiste em ordenar a produção dos lotes, de forma a minimizar o número de preparações necessárias, que consomem capacidade produtiva, e evitar os riscos de contaminação residual. O principal diferencial deste problema em relação aos tratados na literatura é a estrutura dos tempos de preparação. A partir de um estudo de caso em uma empresa do setor, são propostas quatro abordagens para modelar e resolver o problema. As duas primeiras abordagens são baseadas no modelo Genérico de Dimensionamento e Seqüenciamento de Lotes (GLSP) com tempos de preparação dependentes da seqüência. As outras duas abordagens consistem em uma reformulação do modelo GLSP, considerando o seqüenciamento dos lotes como um problema do caixeiro viajante assimétrico (ATSP). Cada uma das abordagens de modelagem GLSP e ATSP são propostas para duas estratégias da empresa em relação à limpeza da linha, denominadas: (1) 'Seqüências Independentes', onde se pressupõe que ao final de cada período do planejamento é realizada uma limpeza completa na linha de produção; e, (2) 'Seqüências Dependentes', onde a seqüência no início de cada período depende do estado de preparação da linha no período anterior (*setup carryover*). O modelo GLSP 'Seqüências Independentes' é resolvido pelo método *branch-and-cut* (utilizando o *software* AMPL/CPLEX), com tempo computacional limitado. Para resolver o modelo GLSP 'Seqüências Dependentes', além do método *branch-and-cut*, são propostos dois procedimentos heurísticos *relax-and-fix*. Para resolução do modelo ATSP 'Seqüências Independentes' é utilizado o método de eliminação de sub-rotas (*sub-tours*). No caso do modelo ATSP 'Seqüências Dependentes', além do método de eliminação de sub-rotas, é utilizado o método de combinação de sub-rotas (*patching*). De acordo com experimentos realizados com dados reais, os modelos e métodos propostos resolvem satisfatoriamente o problema, obtendo resultados melhores que a empresa. Entre as diferentes abordagens propostas, a mais adequada para o problema parece ser a reformulação ATSP com o método de eliminação e combinação de sub-rotas e a estratégia 'Seqüências Dependentes'.

Palavras-chave: Dimensionamento de lotes, Seqüenciamento da produção, Indústria de nutrição animal, GLSP, ATSP, heurísticas *relax-and-fix*.

ABSTRACT

This work studies the integrated lot sizing and scheduling problem in the animal feed compound industry. The lot sizing problem in this industry consists of deciding which and how much to produce in each period, in order to minimize overtime and storage costs. The sequencing problem consists of sequencing the production lots, in order to minimize the setups (that eat into the available capacity), and to avoid the risks of residual contamination. The main difference of this problem in relation to the ones in literature is the structure of the setup times. Using a case study in a company of the sector, four approaches are proposed to model and solve the problem. The first two are based on the General Lot Sizing and Scheduling Problem (GLSP) with sequence dependent setup times. The other two approaches consist of a reformulation of the GLSP model, considering the lot sequencing as an Asymmetric Travelling Salesman Problem (ATSP). Either modeling approach GLSP and ATSP is proposed for two company strategies related to the cleaning of the production line, called (1) 'Independent Sequences', where it is assumed that at the end of each period a complete cleaning in the production line is carried out; and (2) 'Dependent Sequences', where the sequence at the beginning of each period depends on the preparation state of the line in the previous period (setup carryover). The model GLSP 'Independent Sequences' is solved by the branch-and-cut method (using the software AMPL/CPLEX), with limited computational time. To solve the model GLSP 'Dependent Sequences', besides the branch-and-cut method, two heuristic relax-and-fix procedures are proposed. To solve the model ATSP 'Independent Sequences' the subtour elimination method is used. In the case of the model ATSP 'Dependent Sequences', as well as the subtour elimination method, the patching subtours method is used. According to experiments carried out with real data, the models and methods proposed solve the problem satisfactorily, getting better results than the company. Of the different approaches proposed, the most appropriate for the problem appears to be the reformulation ATSP with the patching method and the strategy 'Dependent Sequences'.

Keywords: lot sizing, sequencing, animal feed industry, GLSP, ATSP, relax-and-fix heuristics.

LISTA DE FIGURAS

1.1	Metodologia da Pesquisa Operacional	15
2.1	Produção dos 10 principais países produtores de rações balanceadas em 2005	18
2.2	Fluxograma com os possíveis processos de fabricação em nutrição animal.....	26
2.3	Tipos de ração quanto ao formato	26
2.4	Fluxograma dos processos de fabricação UPS	30
2.5	Planejamento da produção da empresa estudada	33
2.6	Fluxograma do Planejamento da Produção da empresa estudada	34
3.1	Desigualdade triangular para os custos de <i>setup</i>	52
4.1	Representação das estratégias de limpeza completa da linha de produção.....	67
4.2	Fluxo de materiais para o balanceamento de estoque (4.2)	72
4.3	Esquema para ilustrar a capacidade produtiva (restrição 4.3)	73
4.4	Exemplo ilustrativo que viola a desigualdade triangular	75
4.5	Exemplo ilustrativo de seqüência GLSP e ATSP.....	81
4.6	Ilustração das restrições ATSP: (a) 4.27; (b) 4.28; e (c) 4.29.....	85
4.7	Ilustração das sub-rotas	86
4.8	Ilustração do seqüenciamento gerado pelas restrições (4.45)-(4.52)	90
4.9	Ilustração da heurística de combinação de sub-rotas (<i>patching</i>)	94
5.1	Resultados do exemplo simplificado (Exp. 0)	99
5.2	Seqüenciamento para o exemplo simplificado (Exp. 0)	100
5.3	Seqüenciamento para o experimento 1	101
5.4	Resultados do experimento 2	103
5.5	Resultados do experimento 3	104
5.6	Seqüenciamento para o experimento 3	104
5.7	Resultados do experimento 4	105
5.8	Seqüenciamento para o experimento 4	105
5.9	Gráficos ilustrando o desempenho computacional de alguns experimentos com modelo GLSP Seqüências Independentes.....	110
5.10	<i>Gaps</i> relativos médios dos modelos/ métodos para a estratégia Seqüências Dependentes	118
5.11	Comparação dos programas de produção resultantes para as três estratégias de limpeza semanal	121
5.12	Comparação entre a solução ótima gerada (estratégia Seqüências Dependentes) com a solução praticada pela empresa	123
5.13	Gráfico ilustrando a relação entre os custos de estocagem e horas extras da solução ótima da estratégia Seqüências Dependentes	125
5.14	Gráfico ilustrando o <i>trade-off</i> médio entre custos de estocagem e de horas conforme aumenta-se os custos de estocagem	127
5.15	Impacto da redução de capacidade sobre os valores ótimos da função objetivo	128
5.16	Impacto da redução de capacidade nos <i>gaps</i> de otimalidade	129
5.17	Efeito da concentração da demanda nos valores ótimos da função objetivo ..	131
5.18	Valor médio dos <i>gaps</i> relativos das soluções encontradas pelas diferentes abordagens	132
5.19	Comparação entre tempos computacionais médios dados: reais x aleatórios .	133

5.20	Comparação entre <i>gaps</i> relativos das soluções com demanda aleatória U(0,50)	134
5.21	Comparação dos tempos computacionais médios: demanda aleatória U(0,50)	134
5.22	Comparação dos tempos médios de preparação: dados reais x dados aleatórios	135
5.23	Comparação entre tempos médios de preparação nos experimentos com dados reais e com dados aleatórios	136
5.24	Comparação entre tempos médios nos experimentos com dados reais e com dados aleatórios	145
B1	Etapas na resolução de problemas inteiros no CPLEX	171

LISTA DE TABELAS

5.1	Diferenças entre um problema real e o exemplo simplificado	97
5.2	Parâmetros para o exemplo simplificado e experimentos	98
5.3	Programa de produção gerado pelo modelo GLSP Sequências Dependentes.....	99
5.4	Caracterização dos dados coletados na empresa	108
5.5	Resultados dos modelos GLSP e ATSP Sequências Independentes	109
5.6	Resumos dos Programas de Produção - Sequências Independentes	111
5.7	Resultados do modelo GLSP Sequências Dependentes.....	113
5.8	Resultados do modelo ATSP Sequências Dependentes.....	116
5.9	Resultados das abordagens para a estratégia Sequências Dependentes	117
5.10	Resultados da solução - Sequências Dependentes	119
5.11	Comparação entre estratégias relacionadas à limpeza	120
5.12	Plano de produção ótimo para o mesA	123
5.13	Resultado dos experimentos incluindo <i>setups</i> pequenos	137
5.14	Experimentos: tempos de <i>setup</i> simétricos, desigualdade triangular válida....	138
5.15	Experimentos com tempos de <i>setup</i> aleatórios	139
5.16	Porcentagem de melhores soluções em cada experimento	141
5.17	Porcentagem de soluções factíveis em cada experimento (seq. dependentes).....	142
5.18	Porcentagem de soluções factíveis em cada experimento (seq. independentes).....	143
5.19	Tempo computacional médio de cada abordagem	144
Apêndice A		
A1	Relação de precedência entre os grupos de contaminação	164
A2	Agregação em famílias	165
Anexo A		
A1	Consumo de capacidade por produto i (p_i), custos de manter uma unidade em estoque (h_i)	166
A2	Capacidade disponível (horas) por período (k_t), limite máximo de hora extra permitido por período (u_t) e custos* de hora extra por período (co_t).....	167
A3	Matriz dos tempos de preparação (st_{jis}).....	167
A4	Demandas do produto i no período t	169
Anexo B		
B1	Resultados das variações nos parâmetros CPLEX	172
Anexo C		
C1	Perturbação nos custos de estocagem	175
C2	Perturbação na capacidade	180
C3	Perturbação na demanda	182
C4	Quantidade produzida não inteira $q_{is} \geq 0$	186
C5	Geração de tempos de preparação aleatórios	188

LISTA DE SIGLAS

AMPL	<i>A Modeling Language for Mathematical Programming</i>
ATSP	<i>Asymmetric Travelling Salesman Problem</i>
B&B	<i>Branch-and-Bound</i>
B&C	<i>Branch-and-Cut</i>
CLSP	<i>Capacitated Lot Sizing Problem</i> – Problema de Dimensionamento de Lotes Capacitado
CMRP	<i>Capacitated Material Requirements Planning</i>
CPLEX	<i>Contração de C (linguagem de programação) com o método de solução de programação linear SIMPLEX</i>
CSLP	<i>Continuous Setup Lot Sizing Problem</i> – Problema de Dimensionamento de Lotes com Preparação Contínua
DLSP	<i>Discrete Lot Sizing and Scheduling Problem</i> – Problema de Dimensionamento de Lotes e Programação da Produção Discreto
ELSP	<i>Economic Lot Scheduling Problem</i>
EOQ	<i>Economic Order Quantity</i>
ERP	<i>Enterprise Resource Planning</i>
GA	<i>Genetic Algorithms</i>
GLSP	<i>General Lot Sizing and Scheduling Problem</i> - Problema Geral de Dimensionamento de Lotes e Programação da Produção
GLSP-CS	<i>Conservation of Setup State</i>
GLSP-LS	<i>Loss of Setup State</i>
GLSP-ST	<i>Setup Times</i>
IFIF	<i>International Feed Industry Federation</i> – Federação Internacional das Indústrias de Alimentação Animal
JIT	<i>Just in Time</i>
LB	<i>Local Branching</i>
MIP	<i>Mixed Integer Program</i>
MRP	<i>Manufacturing Requirement Planning</i>
MRP II	<i>Manufacturing Resource Planning</i>
PLSP	<i>Proportional Lot Sizing and Scheduling Problem</i> – Problema de Dimensionamento de Lotes e Programação da Produção Proporcional
PLSP-ML	<i>Multi-level Proportional Lot Sizing and Scheduling Problem</i>
PPCP	Planejamento Programação e Controle da Produção
RINS	<i>Relaxation Induced Neighborhood Search</i>
SA	<i>Simulated Annealing</i>
TS	<i>Tabu Search</i>
TSP	<i>Travelling Salesman Problem</i>
UPM	Unidade Produtora de Microingredientes
UPR	Unidade Produtora de Rações
UPS	Unidade Produtora de Suplementos
VNS	<i>Variable Neighborhood Search</i>

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Apresentação	11
1.2 Objetivos	12
1.3 Justificativas.....	13
1.4 Métodos	14
1.5 Organização do trabalho	15
2 A INDÚSTRIA DE NUTRIÇÃO ANIMAL	17
2.1 Contexto	17
2.2 Desafios para o Planejamento da Produção	21
2.3 Processos de Fabricação	23
2.4 Estudo de Caso	27
2.4.1 A Empresa	27
2.4.2 Processo Produtivo	27
2.4.3 Planejamento Programação e Controle da Produção	31
2.5 Escopo do Trabalho	35
3 DIMENSIONAMENTO E SEQÜENCIAMENTO DE LOTES	37
3.1 Contexto	37
3.2 O Problema de Dimensionamento de Lotes	38
3.2.1 Caracterização do Problema	38
3.2.2 Modelos Matemáticos para o Dimensionamento de Lotes	41
3.3 O Problema de Dimensionamento e Seqüenciamento de Lotes	46
3.3.1 Caracterização do Problema	47
3.3.2 Modelos Matemáticos para o Problema Integrado	48
3.3.3 Reformulações do Problema Baseadas em TSP	53
3.4 Métodos de Solução	58
3.4.1 Métodos Exatos	58
3.4.2 Métodos Heurísticos	59
3.4.3 Heurísticas Baseadas em Programação Matemática	62
4 MODELAGEM DO PROBLEMA NA INDÚSTRIA DE SUPLEMENTOS	66
4.1 Considerações	66
4.2 Abordagens GLSP	69
4.2.1 GLSP Seqüências Dependentes	69
4.2.2 GLSP Seqüências Independentes	78
4.2.3 Métodos de Solução para os Modelos GLSP	79
4.3 Abordagens ATSP	80
4.3.1 ATSP Seqüências Independentes	82
4.3.2 ATSP Seqüências Dependentes	88
4.3.3 Métodos de Solução para os modelos ATSP	92
5 EXPERIMENTOS COMPUTACIONAIS E ANÁLISE DE RESULTADOS.....	96
5.1 Experimentos com exemplo ilustrativo	96
5.2 Experimentos com dados reais	106
5.2.1 Caracterização dos dados coletados	107
5.2.2 Estudos computacionais para a estratégia Seqüências Independentes	108

5.2.3 Estudos computacionais para a estratégia Sequências Dependentes	112
5.2.3.1 Abordagem GLSP	112
5.2.3.2 Abordagem ATSP	115
5.2.3.3 Comparação entre abordagens GLSP e ATSP seqüências dependentes	116
5.2.4 Comparação entre estratégias seqüências dependentes e seqüências independentes	119
5.2.5 Comparação com os Resultados da Empresa	121
5.2.6 Detalhamento do programa ótimo de produção ótimo para o mesA	123
5.3 Experimentos com alteração nos parâmetros	124
5.3.1 Teste 1: alteração no trade-off de custos	125
5.3.2 Teste 2: alteração na capacidade produtiva	128
5.3.3 Teste 3: alterações na demanda	130
5.3.4 Teste 4: relaxação da integralidade das variáveis de dimensionamento de lote	135
5.3.5 Teste 5: alterações na matriz de tempos de preparação	136
5.4 Comparação do desempenho das abordagens	140
6 CONCLUSÕES E PERSPECTIVAS FUTURAS	146
6.1 Conclusões	146
6.2 Perspectivas	150
REFERÊNCIAS BIBLIOGRÁFICAS.....	153
APÊNDICE A. Plano de Agregação dos produtos em famílias	163
ANEXO A. Parâmetros para exemplos reais	166
ANEXO B. Experimentos com variação nos parâmetros CPLEX	171
ANEXO C. Resultados completos dos experimentos com variação dos parâmetros	175

1 INTRODUÇÃO

1.1 Apresentação

A indústria de alimentação animal é uma das que mais cresce em todo mundo, impulsionada pelas preocupações com a segurança alimentar. De acordo com a IFIF (*Internacional Feed Industry Federation* – Federação Internacional das Indústrias de Alimentação Animal), a produção mundial de rações vem crescendo a níveis recordes, produzindo aproximadamente 614 milhões de toneladas (IFIF, 2007). A produção brasileira de alimentos balanceados para nutrição animal é a terceira maior do mundo, apresentando acentuado crescimento nos últimos anos (SINDIRAÇÕES, 2007).

No Brasil, o setor de fabricação de alimentos para nutrição animal sofreu grandes mudanças a partir da década de 1980, saltando de uma produção de 5 milhões de toneladas para mais de 47 milhões de toneladas de ração em 2005, com perspectivas de chegar a 61 milhões em 2009 (Cutait, 2008). As empresas do setor adaptaram-se às novas tecnologias, e buscam constantemente o aperfeiçoamento dos sistemas de produção e otimização da utilização dos recursos produtivos.

Questões relacionadas ao Planejamento, Programação e Controle da Produção (PPCP) exercem um papel importante para o bom desempenho das empresas deste setor, pois envolvem uma grande quantidade de informações que devem ser analisadas simultaneamente, para otimizar a utilização dos recursos envolvidos na produção. Dentro de um contexto de planejamento tático e operacional (médio a curto prazo), as decisões do planejamento incluem questões como o dimensionamento e sequenciamento de lotes de produção. Estas questões envolvem desafios para esta indústria, que possui algumas peculiaridades como, por exemplo, a sazonalidade na demanda por produtos e oferta de matérias primas, a perecibilidade dos produtos e matérias primas, a posição na cadeia produtiva, uma grande quantidade de produtos disputando os mesmos recursos produtivos, bem como, o risco de contaminação residual nas linhas de produção.

O dimensionamento de lotes nesta indústria consiste em determinar quanto produzir de cada produto em cada período, ajustando a capacidade produtiva num ambiente de demanda dinâmica. O sequenciamento de lotes consiste em determinar em que ordem produzir estes lotes de forma a minimizar o total dos tempos de preparação, que são dependentes da seqüência produtiva. Um sequenciamento ruim pode reduzir

significativamente a capacidade da linha de produção. Em geral, os produtos mais contaminantes, do ponto de vista de limpeza da linha, têm maior valor agregado e baixa demanda. O ideal seria agregar os lotes de produção de um mesmo produto para economizar tempos de preparação, entretanto, as incertezas em relação à demanda e maiores custos de estocagem são fatores de risco nesta estratégia.

As decisões de dimensionamento e seqüenciamento de lotes nesta indústria são freqüentemente tomadas de maneira separada na prática, o que pode comprometer tanto a qualidade das decisões em relação aos custos operacionais e ao atendimento de prazos de entrega, quanto o tempo de resposta da empresa às constantes variações de demanda, que acarretam na necessidade de reavaliação periódica de planejamento. De acordo com trabalhos anteriores (Toso, 2003; Toso e Morabito, 2005), o uso de modelos quantitativos para o problema de dimensionamento e seqüenciamento de lotes na indústria de nutrição animal pode ser bastante promissor, uma vez que permite integrar as decisões envolvidas, reduzir custos de produção e melhorar a qualidade das soluções obtidas.

As principais particularidades que distinguem este problema integrado de outros tratados na literatura de dimensionamento e seqüenciamento de lotes são: a estrutura dos tempos de preparação, que não obedece à desigualdade triangular; a necessidade de considerar os tamanhos de lotes como valores discretos; e, as altas taxas de variação de demanda. Além disso, a indústria de alimentação animal tem algumas peculiaridades que podem influenciar a tomada de decisões do planejamento da produção, como: a sazonalidade na demanda por produtos e oferta de matérias primas; a perecibilidade dos produtos; a posição na cadeia produtiva; grande quantidade de produtos disputando os mesmos recursos produtivos; e, risco de contaminação residual nas linhas de produção.

1.2 Objetivos

O objetivo principal deste trabalho é estudar e propor modelos para representar o problema, bem como, métodos de solução para os modelos, de forma que a abordagem modelo/método possa apoiar as decisões relacionadas ao dimensionamento e seqüenciamento de lotes na indústria de alimentação animal, mais especificamente de suplementos para nutrição animal.

Baseados em informações coletadas em visitas a empresas do setor, os modelos

matemáticos propostos pretendem responder às questões: o que e quanto produzir em cada período, de maneira a evitar atrasos no atendimento da demanda, minimizando os custos de estocagem e horas extras; e, qual a melhor seqüência dos lotes, de forma a evitar os riscos de contaminação residual e reduzir o número de preparações (*setup*), que diminuem significativamente a capacidade produtiva.

Considerando que a demanda do setor é bastante dinâmica, estas respostas devem ser obtidas em pouco tempo computacional, para viabilizar a utilização dos modelos como ferramentas de apoio à decisão, que poderão ser usados, por exemplo, para avaliação de diferentes cenários de mercado. Desta forma, pretende-se, além da proposição de modelos para representar adequadamente o problema, estudar e aplicar métodos para resolução dos modelos capazes de produzir boas soluções em pouco tempo de execução.

1.3 Justificativas

As justificativas para este trabalho podem ser analisadas sob dois pontos de vista. O primeiro se baseia no desenvolvimento e na avaliação da aplicabilidade dos modelos para o processo decisório do dimensionamento e seqüenciamento de lotes, com aplicação específica na indústria de suplementos para nutrição animal, que é objeto deste estudo de caso. O segundo ponto de vista foca o estudo e desenvolvimento de técnicas e métodos de solução para o problema em questão, que envolve dificuldades como tempos de preparação dependentes da seqüência produtiva.

A indústria de nutrição animal cresceu muito em todo o mundo nos últimos anos, e as perspectivas de crescimento continuam otimistas. Os trabalhos encontrados na literatura sobre esta indústria se limitam aos aspectos técnicos de produção animal: genética, nutrição, sanidade, etc. Na área de Pesquisa Operacional, os trabalhos que se referem à indústria de ração, contemplam basicamente questões relacionadas ao Problema da Mistura. Não foram encontrados trabalhos que tratem especificamente tópicos como Planejamento Programação e Controle da Produção (PPCP) nesta indústria.

O planejamento, a programação e o controle eficaz da produção determinam a agilidade com que uma empresa responde às necessidades do mercado. Uma constante discussão na área de PPCP é o *trade-off* existente entre flexibilidade produtiva e custos operacionais, por exemplo, atender a demanda em períodos de pico pode resultar em custos adicionais indesejáveis. O planejamento da produção pode ser baseado em diversos custos, dependendo dos critérios de desempenho objetivados por uma empresa, como custos de

produção e mudanças na capacidade produtiva, custos de aquisição e controle de estoques e custos associados a perdas no nível de serviço ao cliente. Devido às particularidades da indústria de nutrição animal, estas questões devem ser analisadas cuidadosamente.

As decisões de dimensionamento e seqüenciamento de lotes afetam diretamente os custos operacionais e a eficiência da empresa em atender ao mercado. O uso de modelos matemáticos e computacionais no PPCP permite a geração e análise de cenários de forma abrangente e rápida para responder às variações de mercado, além de fornecer segurança ao processo de tomada de decisão. Entretanto, os modelos matemáticos que integram as decisões de dimensionamento e seqüenciamento de lotes envolvem a utilização de muitas variáveis de decisão discretas, resultando em problemas de otimização linear inteira mista, em geral de difícil resolução exata em tempo computacional aceitável.

1.4 Métodos

Este trabalho utiliza um método de pesquisa quantitativa, típico de Pesquisa Operacional. De acordo com a tipologia proposta por Bertrand e Fransoo (2002), o trabalho pode ser classificado como um estudo quantitativo de modelagem empírico descritiva. As etapas de desenvolvimento do trabalho seguiram as fases clássicas que compõem um estudo de Pesquisa Operacional (Hillier e Lieberman, 2006):

- a) Definição do problema, coleta e análise de dados;
- b) Formulação de modelos matemáticos para representar o problema;
- c) Desenvolvimento de procedimento computacional para resolução;
- d) Testes e aprimoramento dos modelos desenvolvidos;
- e) Análise dos resultados obtidos e validação dos modelos.

Definir um problema, pela abordagem de Pesquisa Operacional, significa estabelecer os objetivos de desempenho, as alternativas de decisão e as restrições existentes (Andrade, 1989, Jonhson & Montgomery, 1974, Winston, 1991).

Arenales et al. (2007) afirmam que formular um modelo matemático implica em fazer simplificações do problema real, e a validação do modelo depende da solução do modelo matemático ser coerente com o contexto original. A figura 1.1 abaixo apresenta uma síntese da abordagem da Pesquisa Operacional.

Para propor um modelo matemático para o problema em questão é necessário conhecer detalhadamente o processo produtivo envolvido, coletar dados e parâmetros para construção e validação das abordagens propostas. Desta forma, esta pesquisa é baseada no estudo de caso de uma unidade produtiva de uma empresa do setor de nutrição animal, localizada do interior do estado de São Paulo. Trata-se de uma unidade com características típicas do setor, e por isso acredita-se que os resultados obtidos neste trabalho sejam facilmente estendidos ou adaptados para outras unidades.

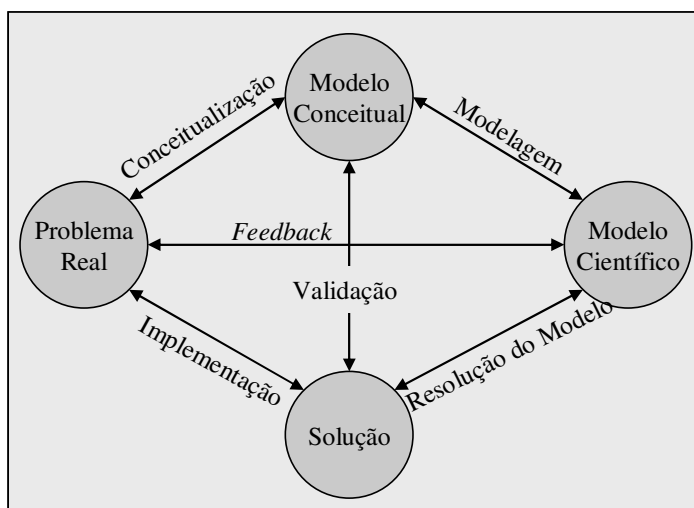


Figura 1.1 Metodologia da Pesquisa Operacional. Fonte: Bertrand; Fransoo, 2002.

1.5 Organização do trabalho

Este trabalho está organizado em seis capítulos. No capítulo 2, é apresentada uma descrição da indústria de nutrição animal, com o objetivo de contextualizar o problema, bem como apresentar as dificuldades relacionadas às decisões de dimensionamento e seqüenciamento de lotes de produção nesta indústria e as delimitações do presente trabalho.

O capítulo 3 apresenta uma revisão bibliográfica dos modelos de dimensionamento de lotes e dos modelos integrados de dimensionamento e seqüenciamento de lotes, bem como métodos exatos e heurísticos propostos na literatura para solução destes modelos.

O capítulo 4 estuda modelos para representar as decisões envolvidas no problema em questão. São propostas duas abordagens distintas: a primeira é baseada no modelo GLSP, uma continuidade dos trabalhos desenvolvidos em Toso (2003) e Toso e Morabito (2005); a

segunda consiste em uma reformulação do problema baseada no modelo ATSP. Para cada abordagem são estudados métodos de solução mais adequados.

O capítulo 5 apresenta os resultados e análises dos testes computacionais que foram realizados em três etapas: estudos com dados ilustrativos para testar a consistência das abordagens propostas; estudos com dados reais, comparando os resultados das diferentes abordagens com as soluções praticadas pela empresa; estudos com dados aleatórios para analisar o desempenho das abordagens diante de parâmetros diferentes.

Finalmente, o capítulo 6 apresenta as conclusões deste trabalho e perspectivas de pesquisa futura. A principal contribuição deste trabalho está na aplicação de modelos e métodos clássicos da literatura de Pesquisa Operacional para representar e resolver o problema de dimensionamento e seqüenciamento de lotes na indústria de suplementos para nutrição animal.

2 A INDÚSTRIA DE NUTRIÇÃO ANIMAL

O objetivo deste capítulo é fazer uma contextualização da indústria de nutrição animal: destacar sua importância econômica, tendências de mercado, posição e papel na cadeia produtiva; apresentar os desafios envolvidos com o planejamento e controle da produção; caracterizar os processos produtivos; e, apresentar o estudo de caso. Cabe ressaltar a dificuldade envolvida em encontrar trabalhos na literatura sobre estas questões neste setor. Quase a totalidade dos trabalhos encontrados sobre a indústria de nutrição animal, tanto no Brasil, quanto no mundo, são artigos focados nos aspectos técnicos de produção animal: genética, nutrição, sanidade, etc., ligadas às áreas: veterinária, zootecnia, agronomia e biologia.

O estudo deste setor foi realizado principalmente por meio de visitas a três plantas industriais de empresas distintas, todas localizadas no interior do estado de São Paulo. Todas as empresas visitadas possuem mais de uma planta industrial, posicionadas estrategicamente mais próximas de seus clientes, como, por exemplo, criadores de gado no Centro-Oeste ou criadores de aves no Sul do país.

2.1 Contexto

A indústria de alimentação animal tem se desenvolvido principalmente desde o começo do século XX, primeiro fornecendo rações para ruminantes e depois atendendo também a demanda para suínos e aves. Mais recentemente, esta indústria tem crescido de maneira acentuada, impulsionada por preocupações como a segurança alimentar. De acordo com o levantamento IFIF (*Internacional Feed Industry Federation* – Federação Internacional das Indústrias de Alimentação Animal), a produção global de rações vem crescendo a níveis recordes, por exemplo, em 2005 foram produzidas 632,7 milhões de toneladas (IFIF, 2007).

O Brasil, juntamente com os EUA, União Européia e China, responde por 70% de toda ração produzida no mundo. Segundo dados do SINDIRAÇÕES (2007) - Sindicato Nacional da Indústria de Alimentação Animal e IFIF (2007), o Brasil ocupa a terceira posição no *ranking* mundial de alimentos balanceados para animais (figura 2.1), com 47,2 milhões de toneladas, que representam 48,2% de toda produção latino americana. Além disso, foram produzidos quase 2 milhões de toneladas de suplementos minerais. O valor estimado do faturamento anual desta indústria em 2005 foi de cerca de US\$ 9,3 bilhões.



Figura 2.1 Produção dos 10 principais países produtores de rações balanceadas em 2005. Fonte: Adaptado de SINDIRAÇÕES (2007).

O desenvolvimento da indústria de nutrição animal tem relação direta com o crescimento da população mundial e aumento de renda, juntamente com outros fatores como: custo das rações e margens de lucro; preocupações com saúde e segurança dos alimentos; além de questões ambientais.

Existem 6,3 bilhões de pessoas no mundo e estima-se que até 2030 serão mais 2 bilhões, sendo que 98% deste crescimento será nos países em desenvolvimento. Além disso, mudanças na renda e no estilo de vida afetam o consumo de carne. Conforme a renda cresce, as famílias gastam mais de sua renda com alimentação, consumindo mais carnes e outros produtos de origem animal ricos em proteína. Espera-se um aumento de cerca de 15 milhões de toneladas de carne nos países desenvolvidos em 20 anos (de 1995 a 2015), e um aumento de 75 milhões de toneladas no mesmo período para países em desenvolvimento (IFIF, 2006).

No Brasil, de acordo com SINDIRAÇÕES (2007), em 2005 o setor de nutrição animal apresentou o maior crescimento dos últimos tempos: 8,9%, contra um crescimento já expressivo de 6,5% do ano anterior. Em 2006, o crescimento do setor foi de 2,4% e a previsão para 2007 é de 6,3%. Em 2005, a avicultura de corte e de postura tiveram um aumento de 9,6% e 8,4%, respectivamente. A suinocultura também se sobressaiu, com desenvolvimento de 7,2%. No segmento de *pet food*, a produção de alimentos cresceu 9%, superando o valor esperado de 8%. Entretanto, o segmento que mais cresceu em 2005 foi a pecuária de corte: a comercialização de rações superou os 13% previstos.

Segundo especialistas, este crescimento pode ser explicado por duas razões em especial: a expansão dos plantéis pecuários, que são fontes de proteína animal para

alimentação humana, e possibilitam o aumento da participação do Brasil nas exportações de carne; e, a oferta abundante de insumos básicos para a produção de rações, como milho, soja e outros ingredientes (SINDIRAÇÕES, 2007). Além disso, o Brasil possui um excelente parque industrial, com as mais avançadas tecnologias de produção disponíveis, ou seja, está preparado para continuar crescendo em ritmo superior à média mundial.

O segmento da indústria de alimentação animal exerce um papel importante na cadeia de alimentos. À jusante fornece os alimentos necessários para a criação de animais saudáveis que fornecem proteína e energia essenciais na alimentação humana. Os produtos de origem animal são importantes fontes de alimentos para pessoas no mundo todo, fornecem 17% da energia e mais de 35% da proteína diária. À montante, os animais consomem um terço do fornecimento global de cereais em grãos. Nos países desenvolvidos onde a produção animal é maior, essa proporção de grãos se aproxima de 60%. Conforme aumenta a demanda por alimentos fontes de proteína animal, aumenta o consumo de grãos. Existe um efeito multiplicador imediato, porque os animais consomem muitos grãos. Por exemplo, é preciso aproximadamente 7 kg de grãos para produzir 1 kg de bife bovino, 4 kg para produzir 1 kg de carne suína e 2kg para produzir 1 kg de frango. De acordo com Chappell (1974) os custos relacionados à alimentação animal correspondem a 60% dos custos totais enquanto cerca de 27% correspondem aos custos de manufatura, transporte e vendas, ou seja, as margens de lucro são pequenas.

Como em todo mundo, a indústria brasileira de rações é um importante elo no cenário agroindustrial. Por um lado, consome cerca de 60% do milho e 35% do farelo de soja do país, apresentando uma estabilidade de mercado para estes produtos. Por outro lado, oferece aos criadores nacionais produtos em constante desenvolvimento tecnológico, possibilitando a exploração de todo o potencial genético e econômico dos animais, tornando-os competitivos no mercado mundial (SINDIRAÇÕES, 2007) (as estatísticas de 2007 ainda não estavam disponibilizadas no *site* até o início de 2008).

A tendência mundial é de aumento crescente no consumo de proteína animal e seus derivados. O Brasil é o maior exportador de carne do mundo, e há um constante crescimento da demanda internacional pela carne brasileira.

Entretanto, alguns fatores influenciam o mercado das carnes, interferindo nos plantéis dos animais e, conseqüentemente, no mercado de rações (SINDIRAÇÕES, 2007). O aparecimento de focos de febre aftosa em alguns estados brasileiros, no fim de 2005, diminuiu os volumes exportados de carnes de bovinos e suínos, pressionando os preços para baixo e causando problemas financeiros para os criadores. Além disso, nos primeiros meses de 2006,

a divulgação de focos de gripe aviária em vários países ocasionou forte impacto no consumo de carnes de aves, principalmente na Europa. O reflexo no Brasil foi imediato, resultando em queda prevista de 400 mil toneladas nas exportações de carnes avícolas. Em função disso, as empresas exportadoras reduziram seus plantéis, o que implicou diretamente em menor demanda de alimentos para animais.

Apesar de alguns cenários de crise, as previsões para o setor são otimistas. O crescimento previsto de 2005 para 2009 é de cerca de 30%, atingindo mais de 61 milhões de toneladas (SINDIRAÇÕES, 2007). Em 2007, é esperado um crescimento de 6,3% em relação a 2006.

Um dos desafios enfrentados pela indústria de alimentação animal, tanto em países desenvolvidos quanto em países em desenvolvimento, é satisfazer a demanda dos consumidores por alimentos seguros. Segurança alimentar é uma questão complexa, envolvendo bem estar e saúde do animal, regulamentações ambientais e governamentais. Os casos de infecções alimentares, causadas por produtos de origem animal, são cada vez mais comuns, sendo amplamente divulgados pelos meios de comunicação.

As preocupações atuais relacionadas à alimentação têm impacto direto na indústria de nutrição animal. Um exemplo disto é o programa de certificação *Safe Feed/ Safe Food* criado pela AFIA (*American Feed Industry Association*), que estabelece uma série de critérios para garantir a segurança de alimentos de origem animal, buscando atuar em toda cadeia produtiva.

Existem ainda outros programas, como sistema de Análise de Perigos e Pontos Críticos de Controle - HACCP (*Hazard Analysis and Critical Control Point*), que consiste em uma ferramenta com enfoque sistêmico para identificar perigos e estimar os riscos que podem afetar a inocuidade de um alimento, bem como procedimentos de controle.

As preocupações mundiais com segurança alimentar refletem-se nas regulamentações impostas, tanto por órgãos governamentais quanto por entidades não-governamentais, para comercialização e exportação de produtos. No Brasil, os Ministérios da Saúde e Agricultura instituíram (Portaria 1428 de 1993) a utilização dos programas Boas Práticas de Fabricação e do HACCP como ferramentas para inspeção de todo o processo de produção da indústria de alimentos (FINEP, 2006).

De acordo com SINDIRAÇÕES (2007), o programa Boas Práticas de Fabricação consiste em um conjunto de normas e procedimentos que visam assegurar a conformidade do produto, ou seja, o atendimento às especificações apresentadas pelos fornecedores, o atendimento à legislação pertinente e às inspeções dos órgãos federais do

setor, e a oferta de alimentos seguros para a saúde do animal, do homem, do trabalhador e do meio ambiente.

O programa Boas Práticas de Fabricação é adotado pela Organização Mundial de Saúde e pelo FDA (*Food and Drugs Administration* dos EUA) como critério mínimo recomendado para fabricação dos produtos sob condições sanitárias adequadas e com rotina de inspeção.

Foram regulamentados a Lei de Biosegurança e o Eurepgap (*Euro-Retailer Produce Working Group* (EUREP) *Good Agricultural Practices* (GAP)). O Eurepgap está reconhecendo o programa brasileiro de Boas Práticas de Fabricação – Avançado, o que permite às empresas certificadas o fornecimento de matérias primas, *premixes* (mistura altamente concentrada) e rações para empresas que exportam carnes para a os supermercados da Europa associados ao EUREP.

Seguindo tendências internacionais de preocupação com a segurança dos alimentos de origem animal, o SINDIRAÇÕES instituiu o programa de certificação *Feed & Food Safety* – Gestão do Alimento Seguro. O programa possui três opções de certificação: Certificação em Boas Práticas de Fabricação; Certificação em Análise de Perigo e Pontos Críticos de Controle; Certificação com Equivalência Internacional (SINDIRAÇÕES, 2007).

2.2 Desafios para o Planejamento da Produção

Conforme apresentado em Toso e Morabito (2005), a indústria de alimentação animal tem algumas peculiaridades que podem influenciar a tomada de decisões do planejamento da produção, como: a sazonalidade na demanda por produtos e oferta de matérias primas; a perecibilidade dos produtos; a posição na cadeia produtiva; uma grande quantidade de produtos disputando os mesmos recursos produtivos; e, risco de contaminação residual nas linhas de produção.

A demanda por produtos é fortemente afetada pela sazonalidade do consumo, por exemplo, com a estiagem durante o inverno, aumenta a demanda por rações bovinas (minerais) em consequência à diminuição das pastagens naturais, ocasionando tanto variações na quantidade produzida quanto variações no *mix* de produtos. Além disso, a sazonalidade na oferta de matérias primas (períodos de entressafra) resulta em variações nos seus custos, forçando uma constante reformulação dos produtos para minimizar custos (*Blending Problem*). As empresas do setor têm dificuldades para ajustar sua capacidade produtiva às

variações de demanda, alternando períodos (meses) onde a produção é para construir estoques, antecipando demandas futuras (*make-to-stock*), com períodos de pico, onde a alternativa é recorrer a horas extras, o que também eleva os custos operacionais.

Uma característica importante dos produtos desta indústria é sua perecibilidade. Na linha de rações comerciais, o prazo de validade (*shelf life*) médio dos produtos é de 120 dias, sendo que é recomendável que produtos com prazo de validade inferior a 60 dias não sejam repassados aos clientes. Isto impõe uma importante restrição ao planejamento da produção: os tamanhos dos lotes – principalmente para produtos muito específicos, com demanda esporádica – não devem exceder a demanda dos próximos períodos, sob o risco de permanecerem em estoque e ultrapassarem o tempo máximo de armazenamento.

A indústria de nutrição animal, principalmente as linhas de rações comerciais e suplementos, está no começo da cadeia produtiva, fornecendo para grandes e pequenos produtores, alguns ligados a grandes grupos alimentícios. Isto implica em grandes pressões por preços, obrigando o setor a racionalização dos custos produtivos, além da exigência do mercado por altos níveis de serviço. Segundo FINEP (2006), os principais elementos competitivos são: eficiência em termos produtivos, ou seja, menores custos com melhores resultados para o criador; preço competitivo; importância da marca e tradição no mercado; serviços oferecidos e assistência técnica prestada; possuir parque industrial próprio com equipe especializada e laboratórios equipados tecnologicamente.

Em nutrição animal as principais linhas de produtos são: rações, concentrados, núcleos e premix. Estes produtos são elaborados para suprir as necessidades nutricionais normais do animal, prevenir enfermidades, melhorar o aproveitamento dos alimentos e estimular o crescimento. Em cada linha há diferentes produtos para fases distintas de crescimento dos animais. Neste segmento existe muita diferenciação entre os produtos, como por exemplo: o desenvolvimento de minerais na forma de orgânicos, lançamento de produtos com diferentes níveis nutricionais, desenvolvimento de produtos sem subprodutos de carne, etc. (FINEP, 2006). Diante deste contexto a variedade de produtos que dividem os mesmos recursos produtivos é significativa.

Outra característica importante desta indústria, que influencia as decisões relacionadas ao seqüenciamento dos lotes, é o risco de contaminação residual entre os produtos. Como vários produtos são fabricados em uma mesma linha, dependendo da ordem em que são produzidos, podem deixar resíduos nos equipamentos, que são contaminantes para os demais. Por exemplo, algumas formulações possuem níveis de cobre que não são aceitáveis

para todos os animais. Esta questão é muito crítica para esta indústria devido à crescente exigência de segurança dos alimentos de origem animal.

2.3 Processos de Fabricação

De acordo com Brito e Stringhini (2006), os processos básicos para fabricação de ração compreendem: recepção, transformação, preparação e finalização. A recepção envolve o recebimento e armazenagem das matérias primas. A transformação consiste em operações, quando necessário, de pré-limpeza, secagem e moagem dos grãos. A preparação compreende as operações de dosagem, mistura e peletização ou extrusão. A finalização, por sua vez, refere-se a operações de ensaque e expedição.

Os grãos, que representam grande volume da matéria prima utilizada na fabricação de rações, geralmente são entregues a granel e despejados em moegas de recepção, que podem ser rodoviárias ou ferroviárias. Após a recepção, os grãos podem passar por processos como limpeza e secagem. Na seqüência, são transportados para os silos de estocagem onde permanecem até utilização.

Apesar de alguns farelos, principalmente o de soja, serem comercializados quase que 100% a granel, grande parte das farinhas e farelos são recebidos, estocados e ensacados. No momento de sua utilização, a sacaria é cortada na moega (dispositivo para transporte do material a granel) de abastecimento interno e o produto é transportado para os silos de processo.

Alguns tipos de farelos, assim como os grãos, são recebidos a granel: chegam pela moega de recepção, passam pelo processo de limpeza e seguem para a armazenagem em silos. São utilizados também armazéns convencionais previamente preparados na tentativa de minimizar os problemas com o manuseio de alguns tipos de farelos, especialmente o de soja. Dois fluxos básicos são normalmente encontrados nas indústrias de rações balanceadas: o convencional e o de moagem conjunta.

No fluxo convencional, adotado em grande parte nas indústrias de rações de todo o mundo, a moagem é separada e serve de preparação dos ingredientes para o setor de dosagem. Os grãos e alguns farelos são transportados individualmente dos silos de estocagem e para silos de pré-moagem e daí, através de alimentadores vão para os moinhos de martelos onde são moídos também em separado. O produto moído fica armazenado até o momento de sua utilização, quando é dosado, e segue para o setor de mistura. A mistura é o processo que dentro de uma fábrica determina a capacidade máxima da planta. Uma boa mistura significa

perfeita homogeneização, o que é influenciado pelas características físicas dos ingredientes, como formato das partículas, tamanho, densidade, carga estática e suas propriedades higroscópicas. Estas características podem aumentar ou diminuir o grau de dificuldade de se obter uma mistura uniforme.

Na moagem conjunta, a matéria prima vai dos silos de estocagem para os silos de dosagem e depois são transportadas para a balança através de roscas dosadoras. Diferente do que acontece no fluxo tradicional, todos os ingredientes são dosados conjuntamente. Após a dosagem, a mistura de grãos e farelos segue para o pré-misturador, que tem como função uma pré-homogeneização dessa mistura, auxiliando assim o trabalho dos moinhos. Neste ponto, existe em algumas instalações a presença de peneiras, com a função de separar produtos já em condições granulométricas adequadas, facilitando assim o trabalho dos moinhos. Nesse sistema, o fato dos moinhos estarem alocados dentro da fábrica permite que a unidade seja mais compacta, além de dispensar a utilização dos silos de pré-moagem e os equipamentos envolvidos no transporte do produto moído até os silos de dosagem.

O composto de grãos e farelos, depois de homogeneizado, é moído e misturado. A partir deste ponto os dois fluxos possíveis, convencional e moagem conjunta, convergem para o mesmo processo. O produto, já em forma de ração farelada, é transportado para os silos de expedição (a granel ou ensaque), ou continuam o processo seguindo para os setores de peletização ou extrusão.

A peletização é um processo mecânico, onde ocorre a aglomeração de pequenas partículas, através do calor úmido e da pressão. Na peletização, a matéria prima (ração farelada) entra no condicionador onde o vapor a uma temperatura de 70 a 90°C é adicionado. Na saída do condicionador, a ração úmida e quente entra na matriz onde é compactada por rolos compressores que comprimem a ração através dos furos do anel. A ração que passa através dos furos do anel é cortada por facas ajustáveis de acordo com o comprimento desejado para os peletes (espécie de grãos). Os peletes quentes e úmidos passam pelo resfriador para a diminuição da sua temperatura, possibilitando a armazenagem e o manuseio, sem alterar a qualidade. Quando necessário, os peletes são triturados por rolos na saída do resfriador, que tem regulagem de abertura para variar o tamanho da trituração dos peletes. Os peletes são transportados para os silos de ensaque ou silos a granel (Schmidt, 2006).

O processo de extrusão para a produção de alimentos para animais, assim como as demais aplicações na indústria alimentícia (cereais matinais, arroz instantâneo, massa instantânea, produtos de panificação, salgadinhos tipo '*snacks*', amidos modificados, produtos

texturizados) (Mendes, 2003), é um processo industrial usado para modificar as propriedades físicas dos ingredientes ou da ração, e que envolve a compressão controlada do material sob alta pressão. Na extrusão a matéria prima (ração farelada) geralmente passa por um sistema de remoagem antes de ser armazenada nos silos de espera. Na seqüência o material segue para o condicionador, de onde é encaminhado para o canhão extrusor. Da mesma forma que na peletização, o produto deve ser resfriado. Em alguns processos, antes de resfriado, o material extrusado passa por uma peneira e adicionador de líquidos.

A ração pronta, seja ela farelada, peletizada, triturada ou extrusada, passa pela etapa de armazenagem, que envolve os silos de expedição e está diretamente ligada ao tipo de transporte e comercialização do produto. Os grandes consumidores normalmente adotam o sistema de expedição a granel como meio de redução de custos, visto que, neste caso, as embalagens são descartadas. Já as rações comerciais são acondicionadas nos mais diversos volumes, pesos e embalagens, e por isso utilizam-se da expedição direta ou de ensaque.

Na expedição a granel a ração pronta é levada para os silos de expedição que servem de pulmões até a retirada do produto via rodoviária ou em alguns casos ferroviária. As instalações permitem que caminhões graneleiros parem diretamente abaixo dos silos para a operação de carregamento.

Para a expedição por ensaque direto existem vários tipos e modelos de ensacadoras. As mais utilizadas são ensacadoras semi-automáticas, dotadas de pré-pesagem, mas já existem no mercado equipamentos mais modernos.

A figura 2.2 ilustra os principais processos para fabricação de produtos para nutrição animal. Em geral, os fluxos possíveis dependem da apresentação do produto, ou seja, seu formato específico. Para se obter a ração, o produto pode ser triturado, peletizado, extrusado ou farelado (figura 2.3). Já os mixes, núcleos e suplementos são produtos farelados (FINEP, 2006). Desta forma, considerando a figura 2.2 temos os seguintes fluxos possíveis:

- (1) Recepção → Moagem → Dosagem → Mistura → Expedição
- (2) Recepção → Moagem → Dosagem → Mistura → Extrusão → Expedição
- (3) Recepção → Moagem → Dosagem → Mistura → Peletização → Expedição
- (4) Recepção → Moagem Conjunta → Expedição
- (5) Recepção → Moagem Conjunta → Extrusão → Expedição
- (6) Recepção → Moagem Conjunta → Peletização → Expedição




Figura 2.2 Fluxograma com os possíveis processos de fabricação em nutrição animal.



Figura 2.3 Tipos de ração quanto ao formato.

Devido a estas diferenças no fluxo de produção, em geral as fábricas são separadas em unidades produtoras para dois segmentos: rações prontas; e, suplementos, núcleos e *premixes*. Entre as 3 plantas visitadas, uma produz apenas suplementos em 5 linhas de produção com fluxo tipo (1), e as outras duas possuem duas linhas: uma tipo (1) e outra tipo (3). Cabe ressaltar que foram visitadas apenas fábricas do segmento de rações comerciais. Os fluxos que incluem etapas de extrusão são mais comuns nas linhas de produção para o segmento *pet food* (para animais de estimação).

2.4 Estudo de Caso

2.4.1 A empresa

A empresa estudada é de capital 100% nacional e hoje atua nas áreas de desenvolvimento genético para avicultura e suinocultura, produção de fitossanitários e produtos para nutrição animal. A divisão de nutrição animal possui 3 fábricas no Brasil, sendo que a unidade objeto deste estudo de caso localiza-se no interior do estado de São Paulo. Estas unidades têm sua produção voltada para os seguintes segmentos da produção animal: suínos geneticamente melhorados, gado de leite e corte, eqüinos, frangos e aves de postura, e mais recentemente para cães, gatos, peixes e pássaros ornamentais. Esta fábrica produz cerca de 200 produtos entre rações prontas, concentrados, premixes, núcleos e sais minerais para nutrição animal, fornecendo tanto para clientes internos – outros negócios do grupo – como para clientes externos – grandes e pequenos produtores. No segmento de suínos a empresa é líder de mercado. Para alcançar a liderança em outros segmentos, busca alternativas para melhorar o processo de planejamento da produção.

2.4.2 Processo produtivo

A planta industrial objeto deste estudo de caso possui três unidades produtivas (grandes linhas de produção): produção de microingredientes, produção de rações e concentrados, e produção de suplementos.

Unidade Produtora de Microingredientes (UPM)

A unidade de microingredientes é responsável por insumos que são utilizados nas outras duas unidades. Esta etapa produtiva consiste basicamente de uma pré-mistura de alguns ingredientes como remédios, aminoácidos, etc., que, por suas características higroscópicas (ou seja, por terem uma capacidade de alta absorção de água), devem ser misturados antecipadamente a um diluente, para garantir a homogeneidade do produto final. Os produtos desta unidade são altamente perecíveis, devendo ser produzidos em no máximo dois dias antes de sua utilização.

As matérias primas que são utilizadas em maior volume (diluente) são armazenadas em grandes sacos chamados de *bags*; as demais se encontram em recipientes

tampados em um ambiente refrigerado aguardando o processo. Os ingredientes são pesados manualmente e podem ser processados por três misturadores pequenos (com capacidade variando de 48 a 500 Kg).

Esta unidade produtiva também pode processar pedidos pequenos em relação à capacidade produtiva das outras unidades, normalmente produtos muito customizados de baixa demanda.

Unidade Produtora de Ração (UPR)

A unidade de produção de ração e concentrados produz ração – preparo completo, pronto para ser consumido – e concentrados que deverão ser misturados a um diluente (por exemplo, farelo de soja) para serem consumidos. As matérias primas básicas são armazenadas em silos (farelo de trigo, farelo de soja, milho). Quando estas matérias chegam na fábrica, são despejadas em uma moega e transportadas até grandes silos onde aguardam o processamento.

A primeira etapa de processamento nesta unidade é o beneficiamento de algumas matérias primas, como milho e soja, que consiste na moagem e peneiramento para separar impurezas. Estes materiais depois de beneficiados podem ser armazenados em silos intermediários, onde aguardam a dosagem. Assim como na unidade de produção de suplementos, a dosagem pode ser manual ou automática (via silos). As dimensões do misturador são as mesmas da unidade anterior (2000 litros). As etapas de dosagem e mistura do processo de fabricação são idênticas ao processo de suplementos. Alguns produtos desta unidade necessitam de processos adicionais como tratamento térmico, peletização e trituração, que são feitos depois da mistura.

No tratamento térmico, a mistura é umidificada e aquecida para esterilização e, em seguida, é passada por uma prensa onde são formados os peletes, que por sua vez são encaminhados para os silos de ensaque. Os produtos que não necessitam de esterilização térmica são dirigidos para uma prensa interna para completar o processo de peletização. Alguns produtos depois da peletização devem ser triturados para facilitar o consumo do animal.

Desta forma, esta linha de produção opera com três processos alternativos:

A - Dosagem – mistura – silos de descanso – tratamento térmico - peletização - trituração - expedição: rações para melhoramento genético de aves de corte e multiplicação de matrizes são produtos para granjas internas que não necessitam de ensaque.

B - Dosagem – mistura – peletização - trituração – ensaque - expedição: rações peletizadas que são comercializadas embaladas.

C - Dosagem – mistura – ensaque - expedição: rações que não necessitam do processo de tratamento térmico e peletização. Neste caso o processo é idêntico ao da unidade de suplementos.

No processo (A) o gargalo é o tratamento térmico. No processo (B) o gargalo é a etapa de peletização que é feita em uma prensa externa. Para os processos (A) e (B) são necessários os silos de espera intermediários, o que resulta em estoque em processo. No processo (C), assim como na unidade de produção de suplementos, o gargalo do processo é o misturador.

Unidade Produtora de Suplementos (UPS)

A unidade de produção de suplementos produz suplementos vitamínicos: sais minerais, núcleos, premixes e promotores para bovinos, eqüinos, suínos e aves, além de alguns produtos para animais de estimação (linha *pet*). A combinação destas linhas de produtos com os animais, aos quais são destinados, resulta nas famílias comerciais, por exemplo: núcleos suínos, núcleos aves ou premix aves.

A maioria das matérias primas utilizadas são de origem mineral (calcáreo, caulim). Algumas matérias primas básicas, que são utilizadas em grande quantidade, são armazenadas em silos.

A primeira etapa do processo produtivo é a dosagem das matérias primas, que é feita mediante formulação pré-estabelecida pelo departamento técnico. Esta etapa é parcialmente automatizada, o operador programa o sistema, seleciona o produto desejado e o número de bateladas, e automaticamente as válvulas dos silos liberam o material que é pesado um a um por duas balanças, conforme pode ser observado na figura 2.4. Parte da formulação é pesada manualmente. Os ingredientes da formulação que são adicionados em menor quantidade ficam armazenados em *bags* ou sacos, são carregados na base do misturador ou nas balanças, conforme indicado pelas setas da figura 2.4. Conforme vão sendo dosados, os ingredientes são encaminhados para a pré-mistura, onde aguardam até que toda a formulação seja pesada.




Figura 2.4 Fluxograma dos processos de fabricação UPS.

A próxima etapa é a mistura dos ingredientes que ocorre em três fases: mistura a seco, a adição de líquidos e uma nova fase de mistura. Terminado este processo, a mistura é descarregada no pós-misturador e encaminhada para o ensaque (figura 2.4). Os tempos de processamento de cada fase de mistura dependem do tipo de produto, por exemplo, alguns aditivos e corantes são os mais demorados, cerca de 40 minutos, enquanto que os núcleos e sais minerais demandam o menor tempo de mistura, em torno de 15 minutos.

O processo de produção é intermitente e ocorre em bateladas, que se referem ao lote mínimo produzido em cada operação. A quantidade produzida em cada batelada de produção é limitada pelo tamanho do misturador, aproximadamente 2000 litros. A medida em kilogramas depende da densidade de cada produto, por exemplo:

- a) Núcleos/ rações = 2000 Kg
- b) Premixes = 1440 Kg
- c) Sais Minerais = 2400 kg

Do ponto de vista técnico, a quantidade mínima produzida deve ser a metade do volume do misturador, para que ocorra uma homogeneização eficiente. Do ponto de vista econômico, os tempos e os custos envolvidos na produção são os mesmos estando o misturador completamente cheio ou não, portanto, pode não ser interessante produzir, por exemplo, apenas metade da capacidade volumétrica do misturador. Quando a demanda pelo

produto é pequena em relação ao tamanho do misturador, é utilizada a unidade produtiva de microingredientes.

Enquanto o sistema está processando bateladas de um mesmo produto, ocorre uma sobreposição de atividades. Por exemplo, considere um lote com cinco bateladas. Suponha que em um dado instante a primeira batelada do lote esteja na etapa de ensaque, a segunda batelada esteja no pós-misturador, aguardando o ensaque, a terceira batelada do lote esteja sendo processada no misturador, a quarta esteja no pré-misturador e a quinta esteja na balança. Na troca de um produto para outro, para diminuir os riscos de misturar dois produtos diferentes, a primeira batelada de um segundo lote de produto só pode entrar no sistema quando a última batelada do primeiro lote sair do misturador, ou seja, a dosagem do segundo produto na balança só começa quando o misturador estiver vazio.

Nesta unidade produtiva o misturador em geral é o gargalo da produção, ou seja, a capacidade produtiva depende do tempo de processamento da mistura.

Os processos produtivos das outras empresas visitadas são semelhantes ao da empresa estudo de caso. Uma também possui duas grandes linhas de produção, separadas em ruminantes e não-ruminantes, com configurações dos processos de fabricação bastante semelhantes à UPS e UPR. Outra com cinco linhas de produção com misturadores menores, duas dedicadas à produção de suplementos para exportação, visando reduzir os riscos de contaminação residual, e outras três funcionando como máquinas paralelas para produção dos demais produtos.

2.4.3 Planejamento Programação e Controle da Produção

A sazonalidade dos produtos na empresa estudada faz com que a demanda varie muito entre os períodos do ano, tanto em relação às quantidades demandadas quanto em relação ao *mix* de produtos. Nos meses de junho, julho e agosto, por exemplo, ocorrem picos na demanda, pois estes meses correspondem ao período de seca, quando aumenta o consumo de rações minerais para bovinos. Para contornar este problema, são tomadas as seguintes decisões para ajustar os recursos de produção no médio prazo:

- variar o nível da força de trabalho, por meio de demissão/ contratação, e treinamento de funcionários (a rotatividade de mão de obra é alta na empresa).
- utilizar horas extras nos meses de pico, ao invés de construir estoques de um mês para outro, devido ao risco relacionado à perecibilidade dos produtos.

Estas decisões estabelecem a capacidade disponível para a produção em cada mês, ou seja, a capacidade normal do período (que varia com o número de funcionários) e a disponibilidade de utilização de horas extras. Cabe salientar que estas decisões precedem as decisões de dimensionamento dos lotes de produção e, conseqüentemente, de seqüenciamento da produção.

Para o dimensionamento de lotes, primeiramente uma pesquisa de campo é realizada pelo departamento comercial, que resulta em um programa mensal de necessidades dos clientes. Este programa é desdobrado semanalmente pelos departamentos comercial e PPCP, resultando em uma previsão semanal.

Com este desdobramento semanal tem-se uma previsão de demanda inicial, que serve como ponto de partida para a programação da produção a cada semana. Portanto, para determinar o que será produzido na primeira semana do mês, o programador considera a previsão inicial de demanda (para aquela semana do mês), mais eventuais pedidos extras ou cancelamentos que recebe do departamento comercial. Considera o saldo disponível ou estoque inicial, o histórico de vendas de cada produto, a disponibilidade de capacidade produtiva no período, e eventuais peculiaridades relativas a determinados clientes, cujos volumes de compra são maiores que a média. Desta forma, a cada semana as previsões de demanda são reavaliadas para determinar o que será produzido dentro de um mês fixo, ou seja, não é utilizado o conceito de horizonte rolante.

De acordo com o histórico de vendas da empresa, a previsão mensal das necessidades dos clientes geralmente se confirma. Entretanto, é difícil prever como será a distribuição da demanda ao longo do mês, ou seja, alguns clientes compram produtos semanalmente, enquanto outros podem fazer seus pedidos na primeira ou na última semana, por exemplo. Desta forma, o desafio do planejamento consiste em elaborar um plano de produção que atenda completamente todas as demandas semanais, não ultrapassando os limites de capacidade disponível, com as alternativas de estocar de uma semana para outra ou utilizar horas extras.

Como a empresa produz para estoque, baseando-se em previsões de demanda, as atividades de planejamento, produção e distribuição se sobrepõem semana a semana, da seguinte forma: na semana 1 é elaborado o plano do que e quanto produzir na semana 2 para ser distribuído na semana 3, conforme pode ser observado na figura 2.5. Quando algum cliente faz um pedido maior que o previsto ou cancela um pedido, deve ser feita uma adequação no dimensionamento de lotes e seqüenciamento na produção para esta semana, o

que interfere diretamente no plano de produção, ou seja, na programação das semanas seguintes, e na seqüência que está sendo produzida.

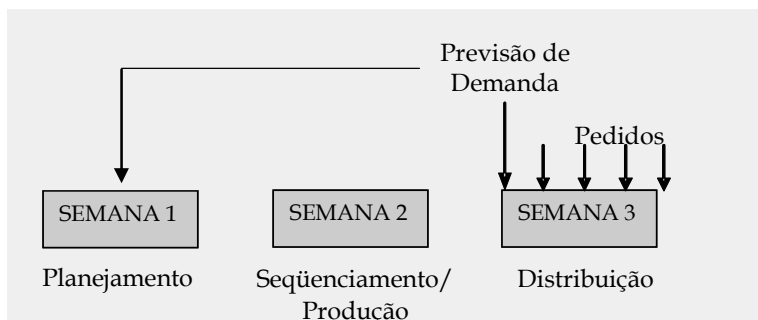


Figura 2.5 Planejamento da produção da empresa estudada.

Na figura 2.6 é apresentado um diagrama de fluxo do processo de planejamento da empresa. Observe nesta figura que, a previsão da demanda mensal inicia o processo de planejamento (elemento 1 do diagrama). A partir do desdobramento semanal e entrada de pedidos, os lotes são dimensionados para cada semana. Uma vez determinado os tamanhos de lotes, são verificados os limites da capacidade produtiva, considerando-se também a possível utilização de horas extras. Se existe capacidade disponível para os tamanhos de lote definidos, são emitidas ordens de fabricação para as unidades produtivas (conforme símbolo de documentação em diagrama, na figura 2.6), caso contrário os lotes são redimensionados, por exemplo, com negociação de novos prazos de entrega. O seqüenciamento dos lotes durante a semana é realizado pelo supervisor de produção, que se baseia nas ordens de fabricação e verificação das posições de estoque. Paralelamente ao seqüenciamento da produção são realizadas atividades de planejamento e compra de materiais (atividades 6 e 7 do diagrama, figura 2.6). Após a produção (atividade 9) é gerada nova documentação (ordens de fabricação produzidas) e envio dos produtos para armazenamento.

Como algumas formulações de produtos misturam diversos tipos de medicamentos e minerais, o seqüenciamento dos lotes deve ser feito de forma a evitar que produtos com agentes contaminantes deixem resíduos na linha de produção (contaminação cruzada ou residual) que comprometam a qualidade do próximo lote. O departamento técnico classifica os produtos por grupos de contaminação, e estabelece uma regra geral para evitar a contaminação residual. Por exemplo, os produtos do grupo 50 não devem ser produzidos depois dos produtos dos seguintes grupos: 888, 777, 999, 666 e 170 (todas as relações de precedência para evitar contaminação encontram-se no apêndice A – tabela A1). Estas restrições à seqüência produtiva são informadas aos supervisores de produção por meio das

ordens de fabricação, portanto, ao montar a seqüência de produção, eles devem estar atentos para estas informações.

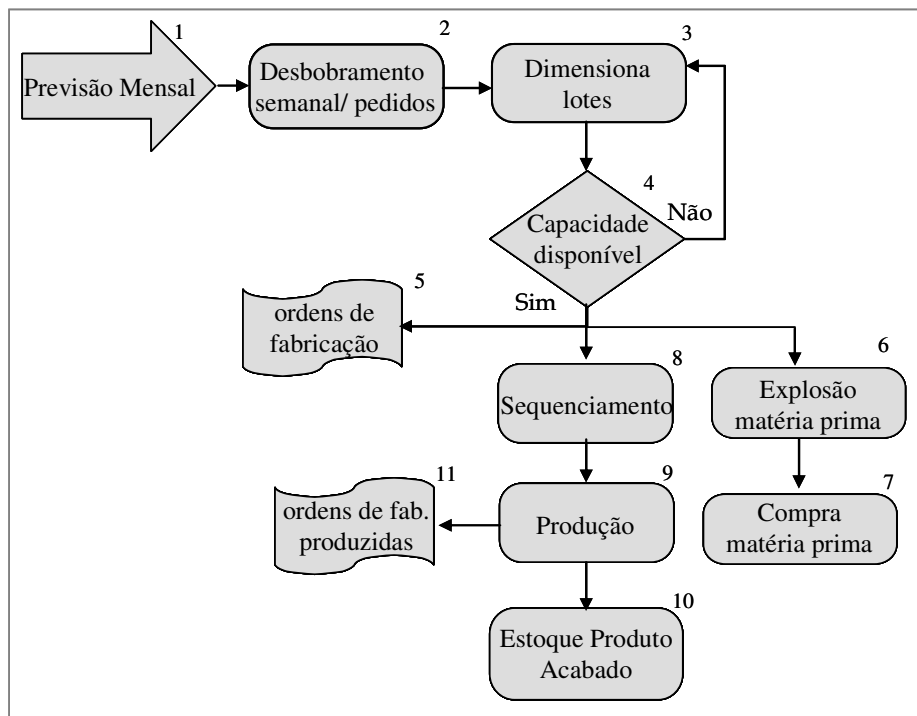


Figura 2.6 Fluxograma do Planejamento da Produção da empresa estudada.

Para evitar a contaminação residual há duas alternativas: procurar uma seqüência ótima em que nenhum produto contamine os demais; ou, quando não é possível obter uma seqüência em que não ocorra contaminação, é necessário fazer uma limpeza nos equipamentos, o que resulta em um tempo de preparação (*setup*) adicional. O tempo de preparação da linha para mudar de um lote para outro é cerca de cinco minutos. Quando é necessário fazer a limpeza, este tempo sobe para cerca de uma hora e quarenta minutos, ou seja, o tempo de preparação é dependente da seqüência produtiva.

No dimensionamento de lotes, a capacidade produtiva é considerada em termos das horas disponíveis para produção no mês e de uma taxa média de produção por hora. Não é considerado o fato de que os tempos de preparação são dependentes da seqüência produtiva, ou seja, que diferentes programas resultam em seqüências diferentes, sendo que algumas podem demandar um maior consumo de capacidade devido à necessidade de mais preparações, podendo inviabilizar alguns programas de produção. Portanto, a empresa freqüentemente tem dificuldades em coordenar de forma eficaz o dimensionamento de lotes

com a programação (seqüenciamento) da produção, pois uma vez definidos os tamanhos de lote, pode não ser possível encontrar uma seqüência de produção que seja viável do ponto de vista da capacidade disponível.

Outra atividade realizada pelo PPCP depois da decisão sobre a capacidade disponível é a explosão das necessidades de matérias primas, por meio da ferramenta MRP (*Material Requirement Planing*), conforme determina o plano de produção. Estas necessidades são encaminhadas ao setor de suprimentos que planeja e executa as compras, disponibilizando os materiais para as unidades produtoras.

Para o controle da produção, cada ordem de fabricação depois de produzida é encaminhada de volta ao PPCP, onde é cadastrada no sistema de informação, que automaticamente atualiza os estoques das matérias primas utilizadas e dos produtos acabados.

Note na figura 2.6 que, ao contrário de um sistema de produção ‘*make-to-order*’, onde a produção ocorre apenas quando ocorre pedidos, a entrada de pedidos no sistema não é o gatilho do processo produtivo, embora seja para as atividades de distribuição e expedição.

2.5 Escopo do trabalho

Como pode ser observado na seção anterior, as unidades produtivas da empresa de nutrição animal estudada possuem processos bastante diferentes, o que dificulta a concepção de um único modelo para todo o sistema. Diante desta dificuldade, optou-se por escolher a unidade produtiva de suplementos para o presente estudo de caso, o que é justificado pelas seguintes considerações:

a) O volume de produção desta unidade, que é bem maior que as demais, respondendo por cerca de 70% da produção da fábrica como um todo. Além disso, a amplitude da sazonalidade dos produtos é maior, o que acarreta problemas em relação à restrição de capacidade, obrigando a unidade a recorrer constantemente à utilização de horas extras para ajustar sua capacidade produtiva;

b) Os produtos fabricados na unidade de suplementos têm um maior valor agregado, o que juntamente com o maior volume de produção contribui para um faturamento superior;

c) O seqüenciamento da produção enfrenta grandes dificuldades devido ao alto risco de contaminação residual de seus produtos, o que não ocorre com a mesma intensidade nas demais áreas;

d) Embora o processo produtivo tenha várias etapas, podemos considerá-lo monoestágio, pois as etapas produtivas estão dispostas em série (linha), o padrão de fluxo de uma batelada é contínuo e basicamente não existe estoque em processo entre as etapas. Além do mais, toda a linha de produção pode ser simplificada como uma única máquina, onde entram as matérias primas e saem os produtos finais, considerando-se o tempo total de produção. Isto facilita a modelagem matemática e a resolução do problema.

Quanto aos processos de planejamento envolvidos, o escopo do trabalho consiste no problema integrado de dimensionamento e seqüenciamento de lotes da produção, o que é justificado pela dificuldade que a empresa tem de coordenar estas etapas, sem incorrer em custos excessivos com estocagem e horas extras. Conforme relatado pelo gerente industrial da fábrica, ao longo do horizonte de planejamento (mês) temos um *trade off* entre produzir maiores quantidades nas semanas de folga, antecipando demandas e pagando os custos de estocagem, ou utilizar horas extras para aumentar a produção nos períodos de maior demanda, o que também incorre em custos adicionais.

3 DIMENSIONAMENTO E SEQÜENCIAMENTO DE LOTES

Neste capítulo apresenta-se uma revisão bibliográfica do problema de dimensionamento de lotes e do problema integrado de dimensionamento e seqüenciamento de lotes, bem como uma breve revisão dos métodos exatos e heurísticos propostos para solução destes problemas. Para uma melhor compreensão, é necessário apresentar alguns conceitos e definições para caracterizar os problemas, bem como discutir o contexto no qual estão inseridos. Desta forma, antes da apresentação e discussão de modelos para dimensionamento e seqüenciamento de lotes, é apresentada uma breve revisão sobre alguns conceitos de PPCP.

3.1 Contexto

Dentro de um ambiente produtivo existem diversos problemas de decisão associados à coordenação dos recursos produtivos. O conjunto das decisões e ações necessárias para coordenar as atividades envolvidas no processo produtivo é entendido neste trabalho como planejamento, programação e controle da produção.

De forma geral, planejar a produção significa estabelecer metas para um período de tempo futuro, chamado de horizonte de planejamento, visando melhorar o uso de recursos produtivos, atendendo as demandas de mercado e antecipando oportunidades de vendas futuras. Para estas atividades são necessárias algumas informações (*inputs*) como: níveis e políticas de estoque; posição de pedidos pendentes (*backorders*); previsões de demanda; estoque em processo; níveis de força de trabalho; capacidade produtiva; disponibilidade de material; padrões de produção; padrões de custos e preços de venda; e, políticas de gerenciamento (Jonhson e Montgomery, 1974; Hax e Candea, 1984; Nahmias, 1995).

Existe uma relação hierárquica entre as atividades de PPCP, entretanto, não existe na literatura um consenso em relação ao horizonte de tempo relacionado a essas atividades. Alguns autores relacionam o Planejamento às atividades de médio prazo onde as decisões são tomadas de forma agregada, em termos do que, quando, onde e como produzir (Kistner e Switalski, 1989; Shapiro, 1993; Gelders e Van Wassenhove, 1981). A Programação da produção está associada às atividades de curto prazo, como por exemplo: determinação dos prazos para execução das atividades e o seqüenciamento de tarefas ou produtos. Já o Controle da produção pode ser definido como a atividade gerencial responsável por regular (planejar,

coordenar, dirigir e controlar) no curto prazo o fluxo de materiais em um sistema de produção por meio de informações e decisões para execução (Burbidge, 1978).

Os objetivos específicos das atividades de PPCP em um ambiente produtivo podem ser: estabelecer as quantidades a produzir de cada produto (dimensionamento de lotes); as quantidades a produzir por um processo ou por diversos processos alternativos (seleção de processos); determinar os níveis de produção para cada estação de trabalho (balanceamento de linha); programar as operações produtivas (*scheduling*); etc. Estes objetivos, bem como todas as atividades do PPCP, devem estar em sintonia com as estratégias globais da empresa (Vollmann *et al.*, 1997). Um sistema de PPCP bem projetado pode fornecer uma vantagem competitiva para a empresa em seu mercado.

Os objetivos do PPCP também estão estreitamente relacionados aos custos e receitas que serão afetados pelos critérios de decisão, por exemplo, custos de produção, custos de estocagem, custos de preparação, etc., que envolvem uma análise das características do negócio/ empresa e dos seus objetivos de desempenho (análise dos *trade-offs*). De acordo com Godinho Filho e Fernandes (2005), quando são projetados os sistemas de produção, devem ser considerados os *trade-offs* existentes na manufatura, ou seja, as empresas devem considerar seus esforços em um número reduzido de objetivos.

Diversos modelos podem ser encontrados na literatura de gerência da produção e pesquisa operacional para tratar problemas de PPCP, conforme, por exemplo, Johnson e Montgomery (1974), Hax e Candea (1984), Winston (1991), Askin e Standridge (1993), Williams (1993), Graves *et al.* (1993), Gershwin (1994) e Nahmias (1995). Estes autores tratam de problemas envolvendo múltiplos produtos, múltiplos processos, múltiplos estágios, limitações de recursos, e outras características comuns ao planejamento da produção envolvendo diferentes objetivos e *trade-offs* entre eles.

3.2 O Problema de Dimensionamento de Lotes

3.2.1 Caracterização do Problema

O problema de dimensionamento de lotes consiste em determinar quando e quanto produzir de cada produto. Este problema está associado a uma das grandes dificuldades do PPCP, que é conseguir flexibilidade nas operações produtivas. Ao contrário dos sistemas de produção em massa, em que se produzem grandes lotes aproveitando-se melhor os tempos de preparação, o surgimento de conceitos como JIT (*Just in Time*) e

manufatura enxuta (*Lean Production*) levaram os sistemas de planejamento a diminuir os tamanhos dos lotes para reduzir os custos de estocagem envolvidos, principalmente os custos de oportunidade financeira, em contrapartida, aumentaram os custos e tempos de preparação (Vörös, 2002).

Quando a taxa de demanda varia ao longo do horizonte de planejamento, este horizonte é dividido em períodos e o problema é determinar níveis de produção adequados para cada período. Algumas alternativas para ajustar a capacidade produtiva às oscilações da demanda são: construir estoques nos períodos de folga na capacidade; atrasar pedidos ou tolerar vendas perdidas; utilizar horas extras para aumentar a capacidade produtiva; utilizar sub-contratação/ terceirização; alterar os níveis de força de trabalho através de contratação e demissão; etc. (Jonhson e Montgomery, 1974; Hax e Candea, 1984). Estas alternativas encontram-se combinadas nos modelos encontrados na literatura de acordo com os critérios de desempenho objetivados.

De acordo com Hax e Candea (1984), quando o processo de manufatura é caracterizado por operações de produção tipo ‘bateladas’, custos de preparação em geral são incorridos para cada lote produzido. Na modelagem matemática do problema de dimensionamento de lotes, estes custos de preparação (por item ou por famílias de itens) devem ser identificados e tratados independentemente, expandindo o número de variáveis e restrições, o que dificulta o tratamento para sistemas de produção em larga escala. Além disso, incluir custos de preparação acarreta na indivisibilidade dos lotes, introduzindo variáveis inteiras na formulação dos modelos.

Os problemas de dimensionamento de lotes podem ser modelados conforme as características de um sistema de produção específico. Conforme Karimi *et al.* (2003), a complexidade destes problemas depende das seguintes características:

- a) Horizonte de Planejamento, que pode ser finito ou infinito. Um horizonte de planejamento finito geralmente é considerado junto com demanda dinâmica, enquanto que o horizonte infinito é considerado para condições de demanda estacionária. Ainda em relação ao tempo, um sistema pode ser observado de forma contínua ou discreta, dividindo os problemas de dimensionamento de lotes em ‘*big-bucket*’ ou ‘*small-bucket*’. Nos problemas ‘*big-bucket*’ os períodos de tempo são grandes o bastante para produzir vários itens, enquanto que em problemas ‘*small-bucket*’ os períodos são pequenos, comportando apenas um ou dois itens.
- b) Demanda. Quanto à demanda os problemas de dimensionamento de lotes podem ser divididos em: estáticos ou dinâmicos; determinísticos ou probabilísticos; dependentes ou

independentes. Quando os valores da demanda não variam ao longo do horizonte de planejamento (são estacionários ou mesmo constantes), a demanda é estática. Quando os valores da demanda mudam ao longo do horizonte de planejamento, a demanda é dinâmica. Se a demanda futura é conhecida (estática ou dinâmica) o problema é determinístico, mas se os valores da demanda futura são baseados em alguma probabilidade, então a demanda é dita probabilística ou estocástica. Na demanda independente, as necessidades de um item não dependem das decisões de dimensionamento de lote de outro item. Conforme explicado adiante, este tipo de demanda é comum nos sistemas de produção único nível. No dimensionamento de lotes multi-nível, a demanda em um nível depende da demanda dos itens anteriores (itens pais), por isso é chamada de demanda dependente. Problemas com demanda dinâmica e dependente são mais complexos que problemas com demandas estáticas ou independentes. Do mesmo modo, os problemas com demandas probabilísticas são mais complexos que os problemas com demandas determinísticas.

c) Número de estágios de produção. Um sistema produtivo pode ser classificado quanto aos estágios do processo de fabricação, resultando em problemas único-nível e problemas multi-nível, também chamados monoestágio ou multiestágio. Os sistemas único nível pressupõem uma única etapa de processamento, onde as matérias primas são diretamente transformadas em produtos finais. Este tipo de produto possui demanda independente. Nos sistemas de produção multi-nível, existem várias etapas de processamento, são produzidos itens intermediários, e existe uma relação de precedência entre estes itens. A demanda de um item em um nível depende da demanda dos itens pais (demanda dependente). Problemas multi níveis são mais complexos que problemas único nível.

d) Número de produtos. O número de itens ou produtos finais em um sistema de produção é uma característica importante que afeta a complexidade da modelagem e resolução dos problemas de dimensionamento de lotes. Desta forma, os sistemas produtivos podem ser divididos em: único item ou multi-item.

e) Restrições de capacidade ou de recursos. A capacidade e os recursos em um sistema produtivo incluem força de trabalho, equipamentos, máquinas, orçamento, etc. Um problema é não capacitado quando não há restrições de capacidade ou recursos, quando existem tais restrições o problema é capacitado. As restrições de capacidade afetam diretamente a complexidade do problema. A resolução de problemas é mais difícil quando existe restrição de capacidade.

f) Estrutura dos custos e tempos de preparação. Os custos ou tempos de preparação geralmente são modelados através da introdução de variáveis binárias no modelo matemático

do problema, causando maior dificuldade para resolução do problema. A estrutura dos tempos ou custos de preparação pode ser simples ou complexa. Se os tempos e custos de preparação são independentes da seqüência de produção, a estrutura é considerada simples, mas quando a preparação é dependente da seqüência, a estrutura é considerada complexa. De acordo com Karimi *et al.* (2003), as estruturas de tempos ou custos de preparação complexas podem ser divididas em três tipos: preparação entre produtos da mesma família; preparação entre famílias; e, preparação que pode ser mantida de um período para outro (*carryover*).

g) Políticas de atendimento da demanda. Dependendo do tipo de empresa ou negócio, pode ser possível permitir estoque negativo (*backlogs*), ou seja, permitir que a demanda atual possa ser atendida em períodos futuros (atrasos), ou mesmo que a demanda não seja totalmente atendida, implicando em perdas nas vendas. Estas possibilidades geralmente são modeladas através da inclusão de custos de atraso na função objetivo e definem a forma das restrições.

h) Percibilidade. Quando existem riscos associados à deterioração dos itens, devem ser consideradas restrições de tempo no horizonte de planejamento, bem como penalizações associadas ao risco de percibilidade.

Usando esta caracterização proposta por Karimi *et al.* (2003), podemos classificar o problema de dimensionamento de lotes da indústria de suplementos para nutrição animal como: monoestágio; multi-item; com horizonte de planejamento finito; demanda dinâmica, determinística e independente; capacitado; com tempos de preparação dependentes da seqüência produtiva; e sem *backlogs*.

3.2.2 Modelos Matemáticos para o Dimensionamento de Lotes

As pesquisas sobre modelos de dimensionamento de lotes começaram com a fórmula clássica de dimensionamento de lotes - EOQ (*Economic Order Quantity*) (Erlenkotter, 1990), que determina a quantidade de produção para um item individual, considerando o *tradeoff* existente entre os custos de controle de estoque e os custos de preparação. Este modelo pressupõe um processo produtivo único nível, sem restrições de capacidade, único item e demanda constante ao longo de um horizonte de planejamento infinito. Embora esta fórmula não seja eficiente para descrever a maioria dos sistemas de planejamento da produção, pois não considera as limitações de capacidade, ela ainda é útil nos sistemas de estoque para determinar quantidades adquiridas de materiais (Nahmias, 1995).

Devido às limitações desta abordagem, surgiram outros modelos, como o ELSP (*Economic Lot Scheduling Problem*) (Elmaghraby, 1978), onde o problema é

programar a produção de mais de um produto em uma única máquina. As principais pressuposições deste modelo são restrição de capacidade, custos e tempos de *setup* independentes da seqüência produtiva, assume ainda taxas de produção e demanda constantes em um horizonte de tempo infinito (Wagner e Davis, 2002, Elmaghraby, 1978).

Uma próxima evolução foi considerar condições de demanda dinâmica. O modelo proposto por Wagner e Whitin (1958) admite um horizonte de planejamento finito dividido em subperíodos, no entanto, não são consideradas restrições de capacidade. As taxas de demanda são conhecidas em cada período e um único lote pode ser produzido por período. O problema é determinar o tamanho de lote em cada período que minimiza a soma total dos custos.

Diversos trabalhos abordam o problema de dimensionamento de lotes não capacitado, considerando a programação da produção (ou aquisição) de um único item com taxas de demanda. Brahimi *et al.* (2006) apresentam uma revisão sobre este problema. A solução ótima do modelo não capacitado único item é encontrada pelo algoritmo de programação dinâmica de Wagner Whitin (Jonhson e Montgomery, 1974, Hax e Candea, 1984). De acordo com Karimi *et al.* (2003), outros autores propuseram abordagens de solução para o problema não capacitado que reduzem a complexidade computacional em relação ao algoritmo proposto por Wagner e Whitin (1958).

Pochet e Wolsey (2006) apresentam um modelo o problema de dimensionamento de lotes não capacitado, que inclui na função objetivo os custos de produção. Estes autores também apresentam uma formulação onde o modelo é estendido para vários produtos simultaneamente. Neste caso temos um modelo não capacitado, único-nível, multi-produto com demanda dinâmica. Como não há restrições de capacidade, o problema pode ser decomposto em N subproblemas independentes, um para cada item a ser produzido. Desta forma, cada subproblema pode ser resolvido independentemente (Pochet e Wolsey, 2006, Araújo e Arenales, 2000, Toledo, 1998, Jonhson e Montgomery, 1974). Para Pochet e Wolsey (2006), o modelo não capacitado é um subproblema essencial para o planejamento da produção, pois é resolvido repetidamente para cada item da estrutura do produto nos modelos de dimensionamento de lotes multi-item ou multi estágio.

Na tentativa de adequar cada vez mais os modelos à realidade, surgiram modelos dinâmicos e capacitados, como o CLSP (*Capacitated Lot Sizing Problem* – Problema de Dimensionamento de Lotes Capacitado) (DeBodt *et al.*, 1984; Drexl e Kimms, 1997; Karimi *et al.*, 2003; Brahimi *et al.*, 2006), que pode ser visto como uma extensão do modelo de Wagner e Whitin (1958). O CLSP é um problema multi-item, único estágio, com horizonte

de planejamento finito dividido em períodos, cada um com uma demanda específica. O CLSP pode ser formulado da seguinte forma:

Parâmetros:

- cs_{it} custo de preparação do produto i no período t ;
 h_{it} custo de manter uma unidade em estoque do produto i no período t ;
 d_{it} demanda do produto i no período t .
 p_i capacidade (tempo) necessária para produzir uma unidade do produto i ;
 C_t capacidade (tempo) disponível no período t .

Variáveis:

- q_{it} quantidade do produto i produzido no período t ;
 I_{it} estoque do produto i no fim do período t ;
 y_{it} variável binária que indica se ocorre preparação para o produto i no período t ($y_{it} = 1$) ou não ($y_{it} = 0$).

$$\min \sum_{i=1}^N \sum_{t=1}^T (cs_{it} y_{it} + h_{it} I_{it}) \quad (3.1)$$

sujeito a

$$q_{it} + I_{i,t-1} - I_{it} = d_{it} \quad t = 1, \dots, T \quad i = 1, \dots, N \quad (3.2)$$

$$p_i q_{it} \leq C_t y_{it} \quad t = 1, \dots, T \quad i = 1, \dots, N \quad (3.3)$$

$$\sum_{i=1}^N p_i q_{it} \leq C_t \quad t = 1, \dots, T \quad (3.4)$$

$$I_{it}, q_{it} \geq 0, y_{it} \in \{0,1\}, \quad t = 1, \dots, T \quad i = 1, \dots, N \quad (3.5)$$

Neste modelo não são permitidos pedidos atrasados (*backorders*). A função objetivo (3.1) minimiza os custos de preparação e estocagem. Pela equação (3.2), a quantidade produzida mais a quantidade em estoque no início de um período, menos a quantidade em estoque no final do período, deve ser igual a demanda do período, ou seja, são equações de balanceamento de estoque. As inequações (3.3) garantem que a produção de um item ocorre somente se a preparação para aquele item ocorrer. As restrições de capacidade são representadas pelas inequações (3.4); observe que nas restrições de capacidade não está

incluído o tempo consumido nas preparações. O CLSP pode produzir vários itens por período (*big bucket*) (Drexl e Kimms, 1997; Brahimi *et al.*, 2006).

Um modelo que considera os tempos de preparação pode ser formulado como o CLSP, modificando-se apenas as restrições de capacidade (3.4) da seguinte forma:

$$\sum_{i=1}^N (p_i q_{it} + st_i y_{it}) \leq C_t \quad t = 1, \dots, T \quad (3.6)$$

onde, st_i são os tempos de preparação para o produto i . Note que o tempo consumido nas preparações reduz a capacidade total do período, enfatizando que o tempo de preparação do processo é um fator crítico para este modelo.

O problema com tempos de preparação não é apenas uma simples extensão do problema com custos de preparação. Quando o número de preparações no plano de produção é modificado, além de um impacto nos custos, ocorre também um impacto no nível de capacidade utilizada (Trigeiro *et al.*, 1989, Billington, 1983, Toledo, 1998, Araújo, 2003).

Encontrar uma solução ótima para o CLSP, mesmo para um único item, é um problema NP-difícil (Florian *et al.*, 1980; Bitran e Yanasse, 1982), ou seja, de grande complexidade computacional. Se no modelo CLSP considerarmos tempos de preparação nas restrições (3.4) como parte do consumo de capacidade (isto é, restrição (3.6)), a complexidade computacional do modelo aumenta e encontrar uma solução factível já é um problema NP-difícil (Maes, *et al.*, 1991, Armentano *et al.*, 1999).

Um exemplo de modelo CLSP único-nível que inclui os tempos de preparação pode ser encontrado em Armentano *et al.* (1999), que propõe uma representação de fluxo de redes. Diferentemente da formulação do CLSP, o modelo também considera os custos de produção na função objetivo, além de um limite superior para a produção do item i no período t . No CLSP apresentado em Drexl e Kimms (1997) este limite é a capacidade total do período.

Pochet e Wolsey (2006), Karimi *et al.* (2003) e Trigeiro *et al.* (1989) formularam um modelo para o problema capacitado considerando, além dos custos de preparação e de estocagem, os custos de produção. A formulação do modelo é igual a formulação do CLSP exceto pela função objetivo:

$$\min \sum_{i=1}^N \sum_{t=1}^T (cs_{it} y_{it} + h_{it} I_{it} + cp_{it} q_{it}) \quad (3.7),$$

onde cp_{it} são os custos de produção do produto i no período t . Outra diferença encontra-se no grupo de restrições (3.3), onde no lugar da capacidade do período C_t , os modelos de Trigeiro *et al.* (1989) e Pochet e Wolsey (2006) usam M (número suficientemente grande). No modelo

de Karimi *et al.* (2003) o parâmetro M refere-se ao limitante superior para produção de um item no período t , e é considerado como a demanda total deste item em todos os períodos.

Na literatura podemos encontrar diversos outros modelos capacitados semelhantes a estes, onde são feitas pequenas alterações na função objetivo, combinando diferentes classes de custos, ou nas restrições, incorporando peculiaridades de sistemas reais. Por exemplo, Hax e Candea (1984) apresentam um modelo capacitado, com força de trabalho fixa, minimizando, além dos custos de produção, preparação e controle de estoques, os custos de horas extras. Se os custos de preparação forem negligenciáveis, o modelo torna-se um modelo de programação linear. Este modelo é interessante para este trabalho por considerar os custos de horas extras. Para apresentar a formulação do modelo, podemos usar as mesmas notações dos modelos anteriores, mais os seguintes parâmetros e variáveis:

Parâmetros:

- r_t custo da força de trabalho por período t
 co_t custo de hora extra por período t
 v_t nível máximo de força de trabalho disponível
 u_t limite máximo de hora extra permitida

Variáveis:

- O_t quantidade de hora extra utilizada no período t
 W_t nível da força de trabalho utilizada no período t

O modelo pode ser formulado como se segue:

$$\text{Min } \sum_{i=1}^N \sum_{t=1}^T (cs_{it}y_{it} + cp_{it}q_{it} + h_{it}I_{it}) + \sum_{t=1}^T (r_tW_t + co_tO_t) \quad (3.8)$$

sujeito a

$$q_{it} + I_{i,t-1} - I_{it} = d_{it} \quad t = 1, \dots, T \quad i = 1, \dots, N \quad (3.9)$$

$$\sum_{i=1}^N (st_i y_{it} + p_i q_{it}) - W_t - O_t = 0 \quad t = 1, \dots, T \quad (3.10)$$

$$0 \leq W_t \leq v_t \quad t = 1, \dots, T \quad (3.11)$$

$$0 \leq O_t \leq u_t \quad t = 1, \dots, T \quad (3.12)$$

$$q_{it}, I_{it} \geq 0 \quad t = 1, \dots, T \quad i = 1, \dots, N \quad (3.13)$$

$$y_{it} \in \{0,1\} \quad (3.14)$$

A função objetivo (3.8) minimiza os custos de produção, custos de preparação, custos de estocagem, custos de variação no nível da força de trabalho e custos de horas extras. As restrições (3.9) são de balanceamento de estoque, enquanto que as restrições (3.10) são de capacidade. Os limites para o nível de força de trabalho e a quantidade de horas extras utilizadas são dados pelas restrições (3.11) e (3.12), respectivamente. A condição de que os custos de preparação sejam considerados somente quando houver produção é imposta em (3.14).

Outros modelos encontrados em Pochet e Wolsey (2006), Billington *et al.* (1994), França *et al.* (1997), Clark e Armentano (1995), Jonhson e Montgomery (1974), Arenales *et al.* (2007), etc., consideram ainda o problema de dimensionamento de lotes multiestágio, ou seja, quando o produto tem uma estrutura onde o item final depende de itens antecessores (relação de precedência), que devem ser programados para produção ou compra. A demanda dos itens finais é independente, enquanto que a dos componentes é dependente. Na prática, o dimensionamento de lotes de produção nas empresas geralmente está baseado na lógica de planejamento MRP (*Material Requirement Planning*) (Drexl e Kimms, 1997; Clark, 2003; Staggemeier e Clark, 2001; Pochet e Wolsey, 2006; Chen e Ji, 2007).

Modelos de dimensionamento de lotes, como o CLSP, não representam todas as decisões envolvidas no dimensionamento de lotes da indústria de suplementos para nutrição animal. Além de não incluir as decisões de seqüenciamento dos lotes, estes modelos não contemplam tempos de preparação dependentes da seqüência produtiva.

3.3 O Problema de Dimensionamento e Seqüenciamento de Lotes

Os problemas de dimensionamento de lotes e seqüenciamento da produção, embora bastante relacionados, são freqüentemente tratados separadamente na literatura. No entanto, conforme Drexl e Kimms (1997), Laguna (1999), Staggemeier e Clark (2001) e Karimi *et al.* (2003), a tendência mais recente é combinar o problema de dimensionamento de lotes às decisões de programação da produção (*lot-sizing and scheduling problems* ou *lot-scheduling*). Nesta seção é apresentada uma breve revisão do problema integrado de dimensionamento e seqüenciamento de lotes, bem como alguns modelos matemáticos para representar o problema e suas variações.

3.3.1 Caracterização do Problema

Conforme apresentado anteriormente, o problema de dimensionamento de lotes (*lot sizing*) consiste em determinar o que e quanto produzir, ajustando a capacidade produtiva às variações de demanda. O problema de seqüenciamento e programação de lotes (*sequencing and scheduling*) consiste em determinar em que ordem produzir os lotes, de forma a minimizar os tempos de preparação, que diminuem a capacidade produtiva (Johnson e Montgomery, 1974; Hax e Candea, 1984; Graves *et al.*, 1994; Gershwin, 1994; Nahmias, 1995).

O método mais utilizado na prática para resolver o problema é o MRP II (*Manufacturing Resource Planning*), que é uma evolução do MRP. O MRP II combina três fases para construir um plano de produção factível. Em uma primeira fase os tamanhos de lote são calculados para todos os itens em todos os níveis da estrutura, ignorando-se as restrições de capacidade. No segundo passo é feito o balanceamento de capacidade nos períodos, alterando-se alguns lotes para encontrar um plano de produção dentro dos limites de capacidade. Contudo, as relações de precedência são ignoradas. E, finalmente, no terceiro passo são tomadas decisões de seqüência e os pedidos são liberados para o chão de fábrica. No entanto, conforme discutido em Drexel e Kimms (1997), a solução deste método pode resultar em longos *lead times*, altos estoques intermediários (*work-in-process*) e pedidos atrasados (*backlogging*).

Outra ferramenta muito usada pelas empresas de manufatura são os sistemas de gerenciamento ERP (*Enterprise Resource Planning*), que além do MRP, disponibilizam outros módulos para o planejamento da produção, como módulo para previsão de vendas, módulo para programação das linhas (*Line Scheduling*), etc. Em alguns *softwares* de sistemas ERP estão incluídos módulos otimizadores que utilizam abordagens de Pesquisa Operacional, por exemplo, o SAP's *Advanced Production Optimizer* (SAP-APO, 2002) e o i2's *Trade Matrix* (i2, 2002); veja, por exemplo, Clark (2003). A maior dificuldade na utilização destes módulos está associada ao fato de que são muito genéricos, não contemplando as especificidades de cada sistema produtivo.

Diversos autores têm apresentado modelos de dimensionamento de lotes para sistemas MRP multiestágios. Por exemplo, Clark (2003) desenvolve três modelos de programação inteira mista e métodos de solução para encontrar um programa mestre de produção capacitado e factível para os sistemas MRP, então chamados modelos CMRP

(*Capacitated Material Requirements Planning*). Uma revisão completa de modelos de dimensionamento de lotes multiestágio pode ser encontrada em Gupta e Keung (1990).

Toledo e Shiguemoto (2005) apresentam um caso particular do problema de dimensionamento de lotes, envolvendo o planejamento da produção de um único item em vários centros produtivos sem restrições de capacidade. O problema pode ser visto como uma decomposição de alguns problemas, como MRP e problemas de dimensionamento de lotes com múltiplos itens e capacidade de produção limitada.

Estas abordagens discutidas até então se relacionam com problemas multi-estágios. Os modelos discutidos na próxima seção tratam de forma integrada os problemas de dimensionamento de lotes e seqüenciamento da produção para problemas monoestágios, que também podem ser utilizados de forma acoplada para modelar os casos multi-estágios.

3.3.2 Modelos matemáticos para o problema integrado

Alguns modelos clássicos que consideram as decisões de sequenciamento de lotes juntamente com as decisões de dimensionamento são: DLSP (*Discrete Lot Sizing and Scheduling Problem* – Problema de Dimensionamento de Lotes e Programação da Produção Discreto); CSLP (*Continuous Setup Lot Sizing Problem* – Problema de Dimensionamento de Lotes com Preparação Contínua); PLSP (*Proportional Lot Sizing and Scheduling Problem* – Problema de Dimensionamento de Lotes e Programação da Produção Proporcional); e, GLSP (*General Lot Sizing and Scheduling Problem* – Problema Geral de Dimensionamento de Lotes e Programação da Produção).

O DLSP consiste em um problema único nível, multi-produto e dinâmico, que foi introduzido para incluir no CLSP as decisões de seqüenciamento (Fleischmann, 1994). Neste problema os períodos considerados são curtos (horas), ao invés de semanas como no CLSP, portanto alguns autores chamam de micro-períodos (Drexl e Kimms, 1997; Staggemeier e Clark, 2001; Araújo, 2003). A pressuposição principal é a produção ‘tudo-ou-nada’, ou seja, somente um item é produzido por período usando toda sua capacidade. Salomon *et. al* (1997) ressaltam a importância prática do DLSP, como por exemplo sua aplicação no sistema de programação da produção automatizado para uma empresa de pneus. Outro exemplo de aplicação do DLSP pode ser encontrado em (Luche e Morabito, 2005; Luche *et al.*, 2007) que propõem modelos para o PPCP da indústria de grãos eletrofundidos.

O CSLP pode ser considerado uma extensão do DLSP, onde a pressuposição ‘tudo-ou-nada’ é abandonada, ou seja, a capacidade por período não tem de ser

completamente utilizada, mas como no modelo anterior, apenas um item pode ser produzido por período. De acordo com Drexl e Kimms (1997), esta diferença em relação ao DLSP permite que após um período de ociosidade, não seja incorrido um novo custo de *setup*. Drexl e Kimms (1997) apresentam uma revisão completa destes modelos.

O PLSP é um modelo mais flexível que os anteriores, admitindo no máximo dois itens por período. De forma geral, a idéia básica do PLSP é usar a capacidade remanescente em um período para produzir um segundo item (Drexl e Haase, 1995). Uma variação deste modelo é o PLSP-ML (*Multi-level Proportional Lot Sizing and Scheduling Problem*) que considera problemas multi-estágios e várias máquinas (Meyr, 2002).

Segundo a classificação de Karimi *et al.* (2003), os modelos DLSP, CSLP e PLSP são modelos ‘*small bucket*’, ou seja, somente um ou dois itens podem ser produzidos em cada período. Para aplicação destes modelos, os períodos de produção devem ser definidos de forma que seu tamanho seja coerente com os tamanhos de lote. Por exemplo, na indústria de suplementos para nutrição animal as quantidades demandadas variam muito de um produto para outro, o que faz com que os tamanhos de lote para produção variem muito. Para aplicação destes modelos seria necessário considerar subperíodos de produção muito pequenos, o que implicaria em um grande número de variáveis. Além disso, o tempo necessário para produção de cada lote depende do tipo de produto, o que dificulta ainda mais a definição do tamanho dos períodos de tempo.

No modelo GLSP (Fleischmann e Meyr, 1997) cada período t é dividido em vários subperíodos s . Cada lote é designado a um subperíodo (s), ou seja, uma posição dentro de cada período (t) para definir uma seqüência. O número de subperíodos dentro de cada período é pré-fixado, mas o comprimento de cada um é função das variáveis de decisão do modelo, podendo inclusive ser nulo.

De acordo com Fleischmann e Meyr (1997), o GLSP é um modelo geral devido ao fato de que diversos modelos para dimensionamento de lotes e seqüenciamento da produção diferem do GLSP apenas por restrições adicionais que modificam a estrutura de tempo das soluções. Segundo estes autores, o grupo de soluções do GLSP contém o grupo de soluções de diversos modelos como CLSP, DLSP e DLSP-SD, CSLP, e PLSP.

Algumas variações do GLSP, que diferem deste apenas no tratamento do estado de *setup* depois dos períodos ociosos, são o GLSP-CS (*Conservation of Setup State*) e o GLSP-LS (*Loss of Setup State*). Para estes modelos, existem casos práticos onde os custos sempre aumentam se uma máquina está ociosa (Fleischmann e Meyr, 1997).

Do ponto de vista do horizonte de planejamento, o modelo GLSP parece ser mais adequado para representar as decisões de dimensionamento e seqüenciamento de lotes da indústria de suplementos para nutrição animal. Entretanto, do ponto de vista da estrutura dos tempos e custos de preparação, ainda não considera que os tempos e custos de preparação são dependentes da seqüência produtiva.

Meyr (2000) apresenta uma variação de modelagem para o GLSP que inclui custos e tempos de preparação dependentes da seqüência produtiva – GLSP-ST (*Setup Times*). Por isso este modelo é especialmente importante para este trabalho. O modelo pode ser formulado da seguinte forma:

Variáveis de decisão:

- q_{is} quantidade do item i produzido no subperíodo s
- I_{it} estoque do item i no fim do período t
- x_{is} variável binária que indica se a máquina está preparada para produzir o item i na posição s ($x_{is} = 1$) ou não ($x_{is} = 0$)
- y_{jis} variável binária que indica se houve mudança do produto j para o produto i no início do subperíodo s ($y_{jis} = 1$) ou não ($y_{jis} = 0$).

Parâmetros:

- C_t capacidade disponível no período t
- h_i custo de manter uma unidade em estoque do item i
- d_{it} demanda do item i no período t
- p_i capacidade necessária para produzir uma unidade de i
- I_{i0} estoque inicial para o item i
- cs_{ji} custo de preparação para mudar do produto j para o produto i – cabe salientar que este parâmetro cs_{ji} é necessário para relacionar os custos de preparação à seqüência produtiva;
- lm_i tamanho de lote mínimo para o item i ;
- st_{ji} tempos de preparação para mudar do produto j para o produto i ;
- N número de itens
- T número de períodos
- S número total de subperíodos
- S_t número de subperíodos s no período t ;

GLSP-ST

$$\text{Min} \sum_{i=1}^N \sum_{j=1}^N \sum_{s=1}^S c_{sj} y_{jis} + \sum_{i=1}^N \sum_{t=1}^T h_i I_{it} \quad (3.15)$$

sujeito a

$$I_{it} = I_{i,t-1} + \sum_{s \in S_t} q_{is} - d_{it} \quad i=1, \dots, N \quad t=1, \dots, T \quad (3.16)$$

$$\sum_{i=1}^N \sum_{s \in S_t} p_i q_{is} + \sum_{i=1}^N \sum_{j=1}^N \sum_{s \in S_t} st_{ji} y_{jis} \leq C_t \quad i, j=1, \dots, N \quad t=1, \dots, T \quad (3.17)$$

$$p_i q_{is} \leq C_t x_{is} \quad i=1, \dots, N \quad t=1, \dots, T \quad s \in S_t \quad (3.18)$$

$$q_{is} \geq lm_i (x_{is} - x_{i,s-1}) \quad i=1, \dots, N \quad s=1, \dots, S \quad (3.19)$$

$$\sum_{i=1}^N x_{is} = 1 \quad s=1, \dots, S \quad (3.20)$$

$$y_{jis} \geq (x_{j,s-1} + x_{is} - 1) \quad i, j=1, \dots, N \quad s=1, \dots, S \quad (3.21)$$

$$x_{is} \in \{0,1\} \quad i=1, \dots, N \quad t=1, \dots, T \quad (3.22)$$

$$I_{it} \geq 0 \quad i=1, \dots, N \quad t=1, \dots, T \quad (3.23)$$

$$q_{is}, y_{jis} \geq 0 \quad i, j=1, \dots, N \quad s=1, \dots, S \quad (3.24)$$

A função objetivo minimiza os custos de manter estoques e de preparação dependentes da seqüência de produção dos lotes. As restrições (3.16) consistem no balanceamento de estoques, que, juntamente com (3.23), garantem que a demanda é atendida sem atrasos. As inequações (3.17) são de restrição de capacidade, e fazem com que a capacidade disponível (tempo) seja reduzida pelos tempos de preparação. As restrições (3.18) e (3.20) determinam que a produção de um item só pode ocorrer se a máquina estiver preparada para ele, e somente um estado de preparação é definido em cada posição s (subperíodo) do período t . Note que se o produto i é produzido no subperíodo s , então o tamanho do subperíodo s é o tempo necessário para produção de i ($p_i q_{is}$), mais um eventual tempo de preparação ($st_{ji} y_{jis}$). As inequações (3.19) são importantes para evitar uma preparação da máquina sem que ocorra efetivamente a produção de uma quantidade mínima, o que poderia resultar em uma avaliação errada acerca dos custos de preparação. Esta restrição é extremamente importante para os casos onde a matriz de custos de preparação não satisfaz a desigualdade triangular (figura 3.1), ou seja:

$$cs_{jk} + cs_{ki} \geq cs_{ji} \quad \forall i, j, k=1, \dots, N \quad (3.25)$$




FIGURA 3.1 Desigualdade triangular para os custos de preparação.

Isto pode ocorrer em alguns processos produtivos onde produzir o produto i depois do j incorre em custos de preparação, no entanto, se existir um produto k que possa ser produzido depois de j para ‘limpar’ o sistema produtivo, então a equação (3.25) é violada. Neste caso precisa-se produzir uma quantidade mínima do produto k (lm_k) para fazer a limpeza, o que é garantido pela restrição (3.19). O tamanho do lote (lm_k) é um parâmetro que depende das características de cada produto, ou seja, a quantidade mínima a ser produzida deve ser determinada de forma que não sobre resíduos de outros produtos (produzidos anteriormente) na linha. Esta questão é de extrema importância para este trabalho, pois no processo produtivo de rações ocorre este problema com a matriz dos tempos de preparação, conforme é visto no capítulo 4.

As inequações (3.21) relacionam os indicadores do estado de preparação da máquina (x_{is}) aos indicadores de mudança de um produto para outro (y_{jis}). Ou seja, se a máquina estava preparada para o produto j no subperíodo ($s-1$) ($x_{j,s-1} = 1$), e está preparada para i no subperíodo s ($x_{is} = 1$), então existe uma preparação de j para i ($y_{jis} \geq 1$).

Conforme discutido anteriormente, este modelo considera que mudar do produto j para o produto i incorre em um tempo de preparação st_{ji} e em custos de preparação cs_{ji} . A seqüência de subperíodos s consecutivos onde um mesmo produto é produzido define um lote deste produto, enquanto a quantidade produzida nestes subperíodos define o tamanho deste lote.

Em Toso (2003) e Toso e Morabito (2005), o problema de dimensionamento e seqüenciamento de lotes da indústria de suplementos é formulado como uma combinação dos modelos GLSP-ST (Meyr, 2000) e de um modelo que considera custos de horas extras (Hax e Candea, 1984).

Uma outra variação do GLSP é o chamado GLSP-PL (*Parallel Machines*), que estende o problema para máquinas paralelas que podem processar quaisquer itens (Meyr, 2002).

Alguns autores, por exemplo, Laguna (1999), Clark e Clark (2000) e Clark (2003), apresentam diferentes modelagens para o problema integrado de dimensionamento de lotes e seqüenciamento da produção com vários itens a serem produzidos por período.

3.3.3 Reformulações do problema baseadas em TSP

Existem na literatura algumas propostas onde o modelo de dimensionamento e seqüenciamento de lotes é reformulado com base no problema do caixeiro viajante ou TSP (*Travelling Salesman Problem*). O TSP é amplamente estudado e pode ser definido da seguinte forma: dado um grafo $G=(V,A)$, onde V é o conjunto de n vértices e A um conjunto de m arcos ou arestas, tal que a cada arco (i, j) está associado um custo (ou distância, ou tempo) c_{ij} , o problema consiste em determinar em G um ciclo Hamiltoniano de custo (ou distância, ou tempo) mínimo. Num grafo orientado, um ciclo (ou circuito) Hamiltoniano é um ciclo com todos os arcos orientados na mesma direção e que passa por todos os vértices uma única vez. O caso assimétrico (ATSP) considera que $c_{ij} \neq c_{ji}$, $i, j \in V$ (Laporte, 1992).

Algumas revisões sobre modelos e métodos para o TSP podem ser encontrados em Lawler *et al.* (1985), Laporte (1992), Junger *et al.* (1995), Carpaneto *et al.* (1995), Gutin *et al.* (2002), Zhang (1997), Zhang (1993), Glover *et al.* (2001), Cirasella *et al.* (2001), Johnson *et al.* (2002), Buriol *et al.* (2005), Orman e Williams (2004). As aplicações mais comuns do TSP estão associadas a problemas de roteamento. No entanto, existem outros problemas que podem ser interpretados como ATSP, entre eles o seqüenciamento de tarefas (Laporte, 1992; Salomon *et al.*, 1997).

Fleishmann (1994) apresenta uma formulação para o DLSP incluindo custos de preparação dependentes da seqüência, depois reformula o problema usando o TSP com janelas de tempo, e propõe um procedimento heurístico para solução.

Inspirados no modelo de Fleischmann (1994), Salomon *et al.* (1997) formulam um problema semelhante que inclui, além dos custos, os tempos de preparação, denominado DLSPSD (*Setup Dependent*). A redefinição do problema em TSP com janelas de tempo é feita da seguinte forma:

- Os nós do grafo representam as ocorrências de demandas de cada produto para cada período, bem como a demanda por períodos ociosos;

- As janelas de tempo sobre os nós garantem que não ocorram atrasos;
- Os custos relacionados aos nós representam os custos de controle de estoques;
- Os arcos representam as transições factíveis entre períodos de demanda e ociosos.
- Os arcos de custos representam os custos das transições de estado, enquanto os arcos de tempo representam os tempos de produção e preparação relacionados às transições de estado.

Salomon *et al.* (1997) resolvem o DLSPSD para instâncias de tamanho moderado por meio de um método ótimo baseado em programação dinâmica. Segundo estes autores, esta abordagem é sensível: ao tamanho do problema; a presença de custos de estocagem; a presença de tempos de preparação dependentes da seqüência; e, à utilização da capacidade.

Pochet e Wolsey (2006) sugerem a utilização da formulação TSP como alternativa para modelar o seqüenciamento de problemas com vários itens, único período, com variáveis dependentes da seqüência produtiva.

Clark e Clark (2000) desenvolveram um modelo para o problema capacitado, multi-item, monoestágio, com tempos de preparação dependentes da seqüência, considerando que os produtos podem ser produzidos em máquinas paralelas, e com permissão de pedidos atrasados (*backorder*). Em um trabalho posterior, Clark (2000) apresenta um método de resolução em que o problema é decomposto: as decisões de dimensionamento de lotes resultam em um modelo linear; enquanto que as decisões de seqüenciamento são remodeladas usando a formulação ATSP. Diferentemente dos trabalhos de Fleischmann (1994) e Fleischmann e Meyr (1997), que apresentam a formulação matemática para o DLSP e depois definem o problema como TSP, o trabalho de Clark (2000) reformula matematicamente o problema, usando equações clássicas do problema do caixeiro viajante para representar as decisões do seqüenciamento de lotes.

O modelo formulado por Clark e Clark (2000) é apresentado a seguir:

Variáveis:

y_{ijmt}^n indica se a n -ésima preparação da máquina m no período t é do produto i para o produto j

x_{imt}^n quantidade produzida do produto i entre a n -ésima e $(n+1)$ -ésima preparação na máquina m no período t (é diferente de zero somente se a n -ésima preparação na máquina m é para o produto i)

I_{it}^+, I_{it}^- estoque/ *backlog* do produto i no fim do período t

Parâmetros:

d_{it} demanda do produto i no período t

A_{mt} tempo disponível na máquina m no período t

s_{ijm} tempo necessário para preparação do produto i para o produto j na máquina m

u_{im} tempo necessário para produzir uma unidade do produto i na máquina m

h_i custo de manter uma unidade de estoque do produto i de um período para outro

g_i custo (penalização) por pedidos atrasados do produto i de um período para outro

j_{0m} produto produzido na máquina m no fim do período zero, ou seja, a configuração inicial da máquina m

$$\text{Min } \sum (h_i I_{it}^+ + g_i I_{it}^-) \quad (3.26)$$

s.a

$$I_{i,t-1}^+ - I_{i,t-1}^- + \sum_{m,n} x_{imt}^n - I_{it}^+ + I_{it}^- = d_{it} \quad \forall i,t \quad (3.27)$$

$$\sum_{j,n} \left[\sum_i s_{ijm} y_{ijmt}^n + u_{jm} x_{jmt}^n \right] \leq A_{mt} \quad \forall m,t \quad (3.28)$$

$$y_{ijm1}^1 = 0 \quad \forall j,m,i \neq i_{0m} \quad (3.29)$$

$$\sum_j y_{i_{0m}jm1}^1 = 1 \quad \forall m \quad (3.30)$$

$$\sum_i y_{ijm,t}^n = \sum_k y_{jkm,t}^{n+1} \quad \forall j,m,t,n = 1, \dots, N-1 \quad (3.31)$$

$$\sum_i y_{ijm,t-1}^N = \sum_k y_{jkm,t}^1 \quad \forall j,m,t = 2, \dots, T \quad (3.32)$$

$$x_{jmt}^n \leq M_{jmt} \sum_i y_{ijmt}^n \quad \forall j,m,n,t \quad (3.33)$$

$$y_{ijmt}^n = 0 \text{ ou } 1 \quad \forall i,j,m,n,t \quad (3.34)$$

$$x_{imt}^n \geq 0 \quad \forall i,m,n,t \quad (3.35)$$

$$I_{it}^+, I_{it}^- \geq 0 \quad \forall i,t \quad (3.36)$$

$$\text{onde, } M_{imt} = \min \left\{ \frac{A_{mt}}{u_{im}}, \sum_{i=1}^T d_{it} + I_{i0}^- - I_{i0}^+ \right\} \quad (3.37)$$

é um limitante superior para x_{imt}^n , uma vez que todos os pedidos atrasados e produção futura do produto i podem, teoricamente, serem produzidos na máquina m .

Diferentemente de outros modelos da literatura, são permitidos atrasos no atendimento à demanda, e, segundo os autores, isto torna o modelo mais realista. Desta forma, a função objetivo considera os custos de manter estoques entre os períodos e os custos por atrasos na demanda.

As equações (3.27) são restrições de balanceamento de estoques, enquanto as equações (3.28) representam os limites de capacidade disponível, considerando tempos de produção e preparação. As restrições (3.29)-(3.33) garantem que a preparação deve ocorrer somente entre um único par de produtos, e que, se ocorre uma preparação para um determinado produto, deve ocorrer uma preparação a partir deste produto.

Pelas restrições (3.34), para que um produto seja produzido em uma máquina em um período, deve ocorrer uma preparação para este produto, ainda que seja o mesmo produto. Para mais detalhes sobre as especificidades deste modelo, ver Clark e Clark (2000). No presente trabalho, o foco da apresentação deste modelo é a decomposição do mesmo, proposta em Clark (2000), onde o seqüenciamento de lotes é reformulado usando a formulação do ATSP.

A abordagem de Clark (2000) é motivada pela dificuldade de resolver o problema para instâncias de tamanho moderado a grande. Desta forma, a alternativa consiste em resolver o seqüenciamento de lotes para cada par máquina-período (m,t) e depois é feito o dimensionamento de lotes para as seqüências encontradas. O dimensionamento de lotes associado com uma dada seqüência de preparação $\{y_{ijmt}^n \forall i, j, m, n, t\}$, que obedece as restrições (3.29)-(3.33), são encontradas resolvendo o seguinte problema linear:

$$\text{Min } \sum_{i,t} [h_i I_{it}^+ + g_i I_{it}^-] \quad (3.38)$$

s.a

$$I_{i,t-1}^+ - I_{i,t-1}^- + \sum_m x_{imt} - I_{it}^+ + I_{it}^- = d_{it} \quad \forall i, t \quad (3.39)$$

$$\sum_{im} u_{im} x_{imt} \leq A_{mt} - \sum_{i,j,n} s_{ijm} y_{ijmt}^n \quad \forall m, t \quad (3.40)$$

onde,

$$x_{imt} \begin{cases} \geq 0 & \text{se o produto } i \text{ deve ser preparado na máquina } m \text{ no período } t \\ = 0 & \text{caso contrário} \end{cases}$$

Para um dado par máquina-período (m, t) e subgrupo desordenado B_{mt} de todos P produtos, é possível minimizar o valor do tempo total para preparações:

$$\sum_{i,j,n} s_{ijm} y_{ijmt}^n \quad (3.41)$$

Encontrar uma seqüência ótima de produtos para minimizar a expressão (3.41) é equivalente a resolver um problema do caixeiro viajante assimétrico (ATSP). Para encontrar boas soluções de forma rápida para o ATSP, a proposta de Clark (2000) é resolver o problema de designação associado, o que resulta em diversas sub-rotas e depois construir uma heurística *patching* agrupando estas sub-rotas em uma única rota ou seqüência de produção. Considerando que a máquina m já está preparada para produzir o tipo i_0 no final do período $t-1$ e deve produzir o tipo j_{99} depois da primeira preparação do período $t+1$, então o problema de designação a ser resolvido é:

$$\text{Min } \sum_{i,j \in B_{mt}} s_{ij} z_{ij} \quad (3.42)$$

s.a

$$\sum_j z_{i_0j} = 1 \quad (3.43)$$

$$\sum_j z_{ij} = 1 \quad \forall j \in B_{mt} \quad (3.44)$$

$$\sum_i z_{ij} = 1 \quad \forall j \in B_{mt} \quad (3.45)$$

$$\sum_i z_{ij_{99}} = 1 \quad (3.46)$$

onde, as variáveis de decisão de designação são:

$$z_{ij} \begin{cases} 1 & \text{se o produto } i \text{ é designado ao produto } j, \text{ ou seja, se ocorre uma preparação do} \\ & \text{produto } i \text{ para o produto } j \\ 0 & \text{caso contrário} \end{cases}$$

Nesta abordagem, o seqüenciamento de lotes é resolvido por busca local e o dimensionamento de lotes por programação linear. A cada iteração da busca local, um algoritmo *patching* é usado para determinar seqüências eficientes de preparação, seguido pelo método dual simplex para determinar tamanhos de lote ótimos para aquela seqüência. Esta abordagem onde as decisões de seqüenciamento de lotes são modeladas como ATSP é uma das alternativas propostas no presente trabalho para tratar o dimensionamento e seqüenciamento de lotes da indústria de suplementos.

3.4 Métodos de Solução

O objetivo desta seção é apresentar uma breve revisão de alguns métodos de solução para os problemas de dimensionamento e seqüenciamento de lotes. Conforme apresentado anteriormente, estes problemas podem ser modelados por programação inteira mista. Outra abordagem para representar o problema consiste na construção de modelos conceituais que podem ser resolvidos por métodos heurísticos, por exemplo, heurísticas construtivas, heurísticas de busca local e metaheurísticas. Devido aos desafios e complexidades dos problemas de dimensionamento e seqüenciamento de lotes, existem abordagens que combinam diferentes métodos de solução, tanto exatos quanto heurísticos. Desta forma, existe extensa literatura sobre métodos de solução para estes problemas.

3.4.1 Métodos Exatos

Os métodos exatos mais utilizados para resolver modelos de programação matemática inteiro-mistos (MIP – *Mixed Integer Program*) são *Branch-and-Bound (B&B)* e *Branch-and-Cut (B&C)*.

O *Branch-and-Bound* é um método de enumeração implícita, cuja idéia básica é a busca da solução ótima por meio da partição do conjunto de soluções possíveis do problema em subconjuntos mais restritos (subproblemas). Cada subproblema fornece limitantes que servem para avaliar a necessidade de novas partições no processo de enumeração. O número de subproblemas cresce exponencialmente com o número de variáveis inteiras, e o tempo computacional de resolução pode se tornar inviável em situações de aplicações práticas.

De acordo com Pochet e Wolsey (2006), uma boa formulação é determinante para resolver um MIP usando o método *Branch-and-Bound*. Uma forma de melhorar o método é adicionar desigualdades válidas na formulação inicial para reduzir a região factível, sem eliminar nenhuma solução inteira. Estas desigualdades válidas são conhecidas como Planos de Corte, que combinadas com o método *Branch-and-Bound* resultam no método *Branch-and-Cut*.

Uma revisão mais detalhada destes métodos pode ser encontrada em Wolsey (1998), Pochet e Wolsey (2006), Arenales *et al.* (2007).

Uma implementação computacional eficiente destes métodos é bastante complexa e exige conhecimentos específicos das áreas de computação e matemática. Desta

forma, a partir das décadas de 50 e 60 houve grande desenvolvimento de algoritmos e códigos de programas para a resolução de problemas complexos de programação matemática, entre eles a programação inteira e a programação inteira mista. Alguns sistemas comerciais eficientes para resolução destes modelos são: CPLEX (ILOG, *Inc.*), LINDO (LINDO *Systems, Inc.*) e XPRESS-MP (*Dash Optimization Ltd.*). De acordo com Atamtürk e Salvesberg (2005), o ‘estado-da-arte’ destes sistemas de programação inteira é um algoritmo *B&B* baseado em programação linear (PL), que tem se tornado cada vez mais complexo com a incorporação de técnicas sofisticadas, como avançadas estratégias de busca, pré-processamento e técnicas de investigação, algoritmos de planos de corte e heurísticas primais. Estes sistemas comerciais para programação inteira e programação inteira mista incluem uma série de estratégias padrão (*default*) que foram escolhidas pelo ajuste a inúmeros exemplares de problemas. A idéia básica é resolver as relaxações lineares o mais rápido possível e fazer ramificações inteligentes (Wolsey, 1998; Bixby, 2002).

3.4.2 Métodos Heurísticos

Devido à sua natureza complexa, a utilização de modelos de programação matemática para o dimensionamento de lotes e para o dimensionamento e seqüenciamento de lotes não é comum na prática. Além disso, o tempo computacional, demandado para resolução destes modelos, frequentemente torna sua aplicação prática inviável. Estudos sobre a complexidade computacional destes modelos podem ser encontrados em Florian *et al.* (1980), Bitran e Yanasse (1982) e Salomon *et al.* (1991). Desta forma, em paralelo ao desenvolvimento de modelos matemáticos, surgiram várias abordagens heurísticas baseadas no conhecimento do problema.

Um método heurístico (também chamado de procedimento inexato, ou, simplesmente, heurística) consiste em um grupo de passos bem definidos para a rápida identificação de uma solução de alta qualidade para um dado problema, onde uma solução é um grupo de valores para um problema desconhecido, e a qualidade é definida por um critério de avaliação (Pureza, 2005). As soluções geralmente são pressupostas factíveis atendendo todas as restrições. O propósito de um método heurístico é identificar boas soluções para o problema com baixo tempo computacional.

De acordo com Karimi *et al.* (2003), a estrutura das heurísticas para os problemas de dimensionamento de lotes pode ser caracterizada em três passos: o dimensionamento dos lotes, uma rotina de factibilização e um passo de melhoria. O passo de

dimensionamento dos lotes consiste em transformar a matriz de demanda em uma matriz de tamanhos de lote de produção, e esta é uma das diferenças entre as heurísticas, ou seja, a forma como elas combinam as demandas em lotes. A rotina de factibilização visa contornar as restrições de capacidade e garantir que toda demanda seja atendida sem atrasos. No passo de melhoria são aplicadas diversas regras para refinar e melhorar a solução encontrada. Neste passo a demanda pode ser dividida em vários lotes, o que geralmente é muito efetivo.

Em Maes e Van Wassenhove (1988) as heurísticas de dimensionamento de lotes são divididas em dois grupos: as heurísticas período-a-período e as heurísticas de melhoria.

As heurísticas período-a-período trabalham construindo a solução do período 1 ao T . Depois de determinar a quantidade a ser produzida para todos os produtos no período t , o excesso de capacidade pode ser utilizado para produzir a demanda dos períodos futuros, visando a economia nos custos de preparação. Para escolher o produto e a respectiva quantidade a ser produzida nos períodos futuros, estas heurísticas utilizam índices de prioridade. Alguns exemplos de heurísticas período-a-período podem ser encontrados em Maes e Wassenhove (1986), Günter (1987), Trigeiro (1989) e Kirca e Kökten (1994).

As heurísticas de melhoria começam com uma solução inicial, geralmente infactível, que pode ser gerada através das técnicas para dimensionamento de lotes não capacitado. Estas heurísticas são compostas de três passos: geração da solução inicial, ignorando-se as restrições de capacidade; tentativas de factibilizar a solução, através de mudanças nos lotes de um período a outro com mínimo custo; e, finalmente, o terceiro passo consiste em minimizar os custos sem permitir soluções infactíveis (Karimi, *et al.*, 2003).

Trigeiro (1989) desenvolveu uma heurística de melhoria para o CLSP com tempos de preparação, baseada na heurística Silver-Meal. A heurística começa com uma solução inicial lote-por-lote, ou seja, o tamanho do lote é igual a demanda em cada período. Para factibilizar a solução é usado um procedimento retroativo, onde a produção da demanda dos períodos com capacidade insuficiente é antecipada nos períodos com excesso de capacidade. O objetivo deste procedimento é minimizar a soma dos custos de preparação e custos de estoques, eliminando a necessidade de horas extras. Finalmente, o algoritmo tenta melhorar a solução através de rearranjos.

Existem muitas heurísticas para os problemas de dimensionamento de lotes, que variam de acordo com as especificidades de cada problema. De acordo com De Boldt *et al.* (1984), a escolha de uma heurística para uma aplicação específica é muito difícil e depende de fatores como a variabilidade da demanda e estrutura de custos. Para uma revisão

mais detalhada sobre métodos heurísticos para problema de dimensionamento de lotes, consultar De Boldt *et al.* (1984) e (Karimi, *et al.*, 2003).

Gupta e Magnusson (2005) consideram o problema de dimensionamento e seqüenciamento da produção com tempos de custos de preparação dependentes da seqüência, assumindo também que a preparação da máquina deve ser mantida de um período para outro (*setup carryover*). Para a resolução deste problema, é proposta uma heurística chamada de ISI (*Initialize, Sequence, and Improve*), que consiste em três passos: busca uma solução inicial factível para determinar as quantidades produzidas; procura encontrar seqüências produtivas com mínimo custo para cada período; e, tenta refinar a solução, buscando antecipar a produção para economizar nos tempos de preparação. Esta heurística pressupõe que a desigualdade triangular é válida para os tempos de preparação, e é testada apenas para instâncias pequenas. Segundo os autores para resolver instâncias grandes, considerar os tempos de preparação dependentes da seqüência é inviável.

De acordo com Jans e Degraeve (2004), na década passada muitas metaheurísticas como Busca Tabu (TS - *Tabu Search*), Algoritmos Genéticos (GA – *Genetic Algorithms*) e *Simulated Annealing* (SA) tornaram-se ferramentas populares e eficientes para resolver problemas de otimização combinatória (Michalewicz e Fogel, 2002; Glover e Laguna, 1997; Reeves (1997).

Sikora (1996) apresenta um Algoritmo Genético para resolver um problema de programação da produção, integrando decisões de dimensionamento de lotes e seqüenciamento de produtos, envolvendo tempos de preparação em cada máquina dependentes da seqüência, restrições de capacidade, capacidade limitada de estoque intermediário entre as máquinas e datas de entrega. Ponnambalam e Reddy (2003) fazem uma adaptação do GA desenvolvido por Sikora (1996) e uma combinação com as técnicas de SA, resultando em um procedimento híbrido de duas fases, que apresenta melhores resultados nos testes realizados. Estes métodos podem ser adaptados para resolver o problema de dimensionamento e seqüenciamento da indústria de suplementos para nutrição animal, entretanto, o maior desafio parece ser a definição de procedimentos de factibilização das soluções encontradas.

Toledo (2007) e Toledo *et al.* (2007) formulam um problema de dimensionamento de lote e programação da produção em máquinas paralelas com restrições de capacidade, custos e tempos de preparação dependentes da seqüência para a indústria de bebidas. O modelo é bastante complexo, apresentando características do GLSP e envolvendo dois estágios e sincronia entre os estágios. A resolução por meio de métodos exatos só é

viável para instâncias pequenas, para isso foi usado o pacote GAMS/CPLEX. Para instâncias maiores foram desenvolvidos dois procedimentos heurísticos: um Algoritmo Genético e um Algoritmo Memético.

Outros trabalhos que aplicam GA ao problema de dimensionamento de lotes e programação da produção podem ser encontrados em Xie e Dong (2002), Staggemeier et al. (2002) e Ozdamar e Barbarosoglu (1999).

Hindi (1995) propõe um algoritmo de Busca Tabu para um problema de dimensionamento de lotes único-item, capacitado, dinâmico, com custos de *start-up* e reserva (*reservation costs*), que encontra soluções ótimas em todos os testes. Pereira *et al.* (2002) combinam as técnicas de Busca Local e Busca Tabu para um DLSP multi-itens, multi-máquinas com custos de preparação dependentes da seqüência.

Uma revisão sobre as possibilidades de aplicação de diversas metaheurísticas para problemas de dimensionamento de lotes dinâmico pode ser encontrada em Jans e Degraeve (2004). Estes autores focam a discussão dos componentes gerais destas metaheurísticas e como elas podem ser implementadas para o problema em questão.

Não foram encontradas na bibliografia pesquisada abordagens heurísticas para o problema integrado de dimensionamento e seqüenciamento de lotes com as mesmas características do problema encontrado na indústria de suplementos para nutrição animal. Conforme mencionado, as maiores diferenças deste problema em relação às abordagens aqui apresentadas são: os tempos de preparação são dependentes da seqüência e não obedecem à desigualdade triangular; as quantidades produzidas devem ser múltiplas de bateladas de produção, isto é, são variáveis inteiras (estas características são mais bem discutidas no capítulo 4).

3.4.3 Heurísticas Baseadas em Programação Matemática

A maioria dos métodos de solução para os modelos integrados de dimensionamento e seqüenciamento da produção utilizam métodos híbridos que combinam heurísticas, decomposições e relaxações (Meyr, 2000), (Fleishmann e Meyr, 1997), (Drexl e Haase, 1995). Entre estes métodos híbridos destacam-se algumas heurísticas baseadas em programação matemática, que podem ser: construtivas, por exemplo, a heurística *relax-and-fix*; ou, heurísticas de melhoria, como *Local Branching* (Fischetti e Lodi, 2003; Pochet e Wolsey, 2006; Hansen *et al.*, 2005; Fischetti e Lodi, 2006), RINS (*Relaxation Induced*

Neighborhood Search) (Danna *et al.*, 2005; Pochet e Wolsey, 2006) e VNS (*Variable Neighborhood Search*) (Mladenovic e Hansen, 1997; Hansen e Mladenovic, 2001; Hansen *et al.*, 2006).

Conforme Pochet e Wolsey (2006), estes métodos heurísticos consistem basicamente na modificação do MIP original por meio da: fixação de algumas variáveis; adição de restrições; ou, relaxação de algumas restrições de integralidade. Ainda de acordo com os autores, existem muitas possibilidades de variações e combinações destas heurísticas, por exemplo, é possível considerar apenas um subconjunto das variáveis; priorizar as variáveis nulas ou as não-nulas; etc.

A heurística *Local Branching* foi proposta por Fischetti e Lodi (2003), para tratar problemas grandes que são comuns em aplicações práticas. Pochet e Wolsey (2006) classificam esta técnica como uma heurística de melhoria, pois seu objetivo é melhorar uma dada solução factível. A idéia básica da heurística *Local Branching* é explorar uma vizinhança a partir de uma solução inteira inicial. Segundo Hansen *et al.* (2006), o *Local Branching* é uma técnica MIP projetada para ser um método exato, mas se um limite de tempo é alocado para resolver o problema, antes que a solução ótima seja encontrada e sua otimalidade provada, o LB comporta-se como uma heurística.

Mendes (2006) aplica a heurística *local branching* para resolver um problema de roteirização e programação de veículos com requisição simultânea de mais de um veículo para atendimento da demanda, restrições de janela de tempo e de precedência entre tarefas.

Outro método recente que vem sendo aplicado para resolver MIP's é a metaheurística de busca em vizinhança variável VNS, originalmente proposta por Mladenović e Hansen (1997). Em Hansen e Mladenović (2001) e Hansen *et al.* (2006), esta técnica é redefinida de forma a combinar a busca local com mudanças sistemáticas da estrutura da vizinhança, para escapar de regiões de ótimo local. A busca em vizinhança variável ocorre por meio da geração de soluções aleatórias em diversas vizinhanças de uma solução, seguidas de busca local. Alguns exemplos de aplicações desta técnica podem ser encontrados em Hansen e Mladenović (2001) e Rocha *et al.* (2007).

Pochet e Wolsey (2006) ressaltam que existem muitas possibilidades de variação, bem como diferentes maneiras de combinação destas heurísticas. Uma heurística particularmente interessante para este trabalho é a heurística *relax-and-fix* que é mais bem detalhada a seguir.

Heurística *Relax-and-Fix*

Considere um MIP: $\min\{cx + fy : Ax + By \geq b, x \in \mathfrak{R}_+^n, y \in \{0,1\}^p\}$. Seja $Q = \{1, \dots, p\}$ o conjunto de índices das variáveis y . Na heurística *Relax-and-Fix* pressupõe-se que as variáveis binárias ou inteiras podem ser particionadas em R subconjuntos disjuntos Q_1, \dots, Q_R de importância decrescente. Então, resolve-se uma seqüência de problemas parcialmente relaxados MIP^r (Pochet e Wolsey, 2006):

$$\begin{aligned}
 MIP^r : \min \{ & cx + fy : Ax + By \geq b \\
 & x \geq 0 \\
 & y_j = \hat{y}_j \quad \text{para todo } j \in \bigcup_{h=1, \dots, r-1} Q_h \\
 & y_j \in \{0,1\} \quad \text{para todo } j \in Q_r \\
 & 0 \leq y_j \leq 1 \quad \text{para todo } j \in \bigcup_{h=r+1, \dots, R} Q_h
 \end{aligned}$$

onde \hat{y}_j é o valor obtido para a variável y_j no MIP^{r-1} .

Cada MIP^r tem um grupo reduzido de variáveis inteiras, cujo número é pequeno o bastante para obter rapidamente soluções ótimas MIP (Clark e Clark, 2000). Conforme a série avança, cada grupo de variáveis inteiras é permanentemente fixado em seus valores da solução.

Algumas aplicações da heurística *Relax-and-Fix* para resolução de modelos de dimensionamento e seqüenciamento de lotes podem ser encontrados em Araújo *et al.* (2007), Ferreira (2006), Ferreira *et al.* (2008), Beraldi *et al.* (2007), Beraldi *et al.* (2006), Alonso-Ayuso *et al.* (2007), Alonso-Ayuso *et al.* (2006).

Araújo *et al.* (2007) aplicam a heurística *Relax-and-Fix* para resolver um modelo de dimensionamento e seqüenciamento de lotes com custos e tempos de preparação dependentes da seqüência. A partição do conjunto de variáveis inteiras é feita em relação aos períodos de programação, mantendo-se a integralidade das variáveis nos primeiros períodos e relaxando os demais. Os resultados mostram que o procedimento *Relax-and-Fix* utilizado gera, dentro do limite de tempo, melhores soluções que o CPLEX (versão 7.1) para os problemas médios e grandes, particularmente situações mais realistas onde os limites de capacidade são mais apertados.

Ferreira (2006) e Ferreira *et al.* (2008) propõem três modelos para o dimensionamento e seqüenciamento de lotes na indústria de bebidas. Os modelos são relativamente complexos, envolvendo dois estágios de produção e sincronia entre os estágios, com estruturas compostas por conjuntos de variáveis que podem ser fixados, resultando em modelos menores e mais tratáveis computacionalmente. Foram propostas 15 estratégias de

heurísticas *Relax-and-Fix* que estão divididas em três grupos. No primeiro grupo, a partição das variáveis é feita por períodos, e as estratégias variam de acordo com o critério de fixação das variáveis. No segundo grupo, a partição é feita usando diferentes combinações dos conjuntos de máquinas, períodos, e estágios. No terceiro grupo, o critério de partição do conjunto de variáveis é baseado nos subperíodos, o que resulta um número maior de subproblemas. As estratégias *Relax-and-Fix* tiveram um desempenho superior em relação às outras estratégias testadas para um dos modelos.

Uma proposta de heurística *Relax-and-Fix* com a estratégia de horizonte rolante é feita em Beraldi *et al.* (2007) para resolver um problema de dimensionamento e seqüenciamento de lotes em máquinas paralelas com custos de preparação dependentes da seqüência produtiva. Estes autores propõem 4 estratégias de partição do conjunto de variáveis inteiras: uma partição baseada nas variáveis de tempo; uma partição das variáveis associadas aos produtos; duas partições híbridas produto-tempo, em uma o período de tempo é dividido e aplica-se uma partição para os produtos em cada intervalo de tempo, e na outra os produtos são particionados primeiro, e depois é usado um procedimento para partição de tempo. Todos os subproblemas resultantes são factíveis.

Beraldi *et al.* (2006) aplicam a heurística *Relax-and-Fix* em um modelo de dimensionamento e seqüenciamento de lotes estocástico multi-estágio, onde as incertezas associadas aos tempos de processamento são representadas por uma estrutura de cenários (árvore de cenários). São exploradas estratégias de partição do conjunto de variáveis considerando a estrutura dos cenários. O algoritmo proposto neste trabalho também considera a possibilidade de surgirem subproblemas infactíveis, e apresenta uma alternativa para evitá-los por meio do reagrupamento dos conjuntos de variáveis. Uma abordagem semelhante é encontrada em Alonso-Ayuso *et al.* (2006).

4 MODELAGEM DO PROBLEMA NA INDÚSTRIA DE SUPLEMENTOS

O objetivo neste capítulo é a proposição de modelos que representem as decisões envolvidas no dimensionamento e seqüenciamento de lotes de produção na indústria de suplementos para nutrição animal. Estes modelos são baseados nos modelos revisados no capítulo anterior.

O problema de dimensionamento e seqüenciamento de lotes de produção na indústria de nutrição animal apresenta variações dependendo da configuração do processo produtivo. Conforme apresentado no capítulo 2, existem processos produtivos que podem ser considerados monoestágio, por exemplo, algumas fábricas produtoras de suplementos, e processos produtivos multi-estágios, por exemplo, algumas unidades produtoras de ração completa. Conforme mencionado antes, o escopo deste trabalho é uma unidade produtora de suplementos.

4.1 Considerações

O problema de dimensionamento e seqüenciamento de lotes na indústria de suplementos pode ser caracterizado como monoestágio, uma máquina, com tempos de preparação dependentes da seqüência. A capacidade da linha de produção é limitada pela capacidade do equipamento gargalo, que no caso desta unidade de suplementos é o misturador. Desta forma, temos múltiplos produtos disputando por recursos limitados sob condições de demanda dinâmica e horizonte de tempo finito. Em geral, nesta indústria não são permitidos pedidos atrasados (*backlogs*).

As previsões de demanda são realizadas mensalmente e desdobradas e ajustadas semanalmente. Conforme discutido anteriormente, a empresa produz para estoque de uma semana para outra e tem como política comercial atender todos os pedidos dos clientes sem atrasos. A alta sazonalidade dos produtos dificulta o balanceamento da capacidade produtiva. Em determinados meses, é possível que ocorra capacidade ociosa, enquanto que em outros é necessário a utilização de horas extras. A programação da produção é feita considerando um horizonte de planejamento mensal, seguindo a previsão da demanda, seu desdobramento semanal, bem como uma reavaliação periódica, considerando as variações entre a demanda real e a originalmente prevista.

O desafio para o PPCP é fazer o dimensionamento de lotes considerando as questões de seqüenciamento com tempos de preparação dependentes da seqüência de produção. Por exemplo, se depois de dimensionados os lotes, entra um pedido não previsto, o programador tem dificuldade de avaliar a viabilidade técnica e, principalmente, o impacto econômico de inserir este pedido na seqüência programada. Cabe ao chão de fábrica repetir todo o processo de seqüenciar os lotes e avaliar a necessidade de utilização de horas extras. A empresa enfrenta problemas para coordenar as atividades de dimensionamento e seqüenciamento de lotes.

Desta forma, conforme o gerente industrial da empresa, basicamente o problema consiste em determinar as quantidades produzidas a cada semana de forma a atender a demanda do período, e encontrar uma seqüência de produção para estes lotes, com o objetivo principal de minimizar os custos de horas extras, e também os custos de manter estoques no período.

Ao final de cada semana de produção, podem ser adotadas duas estratégias relacionadas à limpeza da linha (conforme figura 4.1).

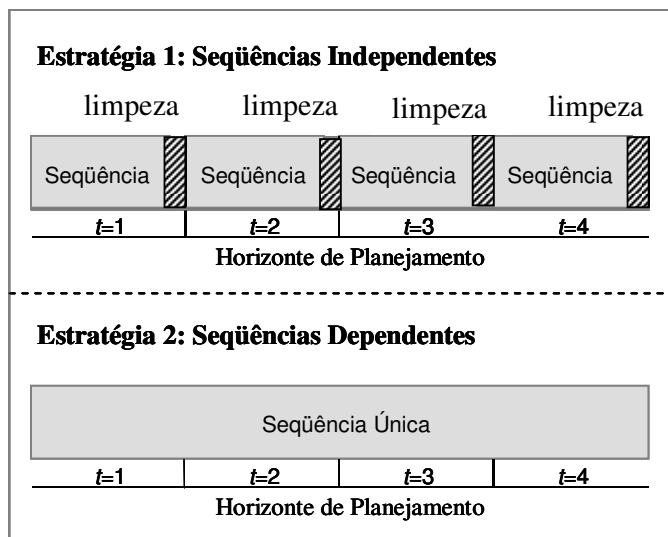


Figura 4.1 Representação das estratégias de limpeza completa da linha de produção.

A estratégia denominada Seqüências Independentes consiste em fazer uma limpeza completa na linha de produção ao final de cada período, deixando a linha preparada para começar o período seguinte com qualquer produto, ou seja, as seqüências em cada período são independentes. Esta estratégia é adotada na prática da empresa, objeto do estudo de caso, para meses com folga de capacidade, em que o tempo utilizado para limpeza não

compromete o atendimento da demanda. O uso desta estratégia também foi observado em outra empresa visitada.

A estratégia denominada Sequências Dependentes consiste em deixar a linha para ser limpa no próximo período, que significa conservar o estado de preparação entre os períodos (*carryover*), ou seja, a seqüência entre os períodos é dependente. Esta estratégia é adotada em períodos de capacidade restrita, onde a limpeza da linha é realizada somente para evitar riscos de contaminação residual.

Para facilitar a formulação matemática e posterior resolução do problema, são necessárias as seguintes considerações:

- a) Os lotes de produção têm tamanhos diferentes dependendo da densidade de cada produto. Como é inviável economicamente produzir menos que uma batelada de cada produto, uma unidade de produção será considerada como uma batelada, independente do seu tamanho (em peso ou volume). As demandas por produto serão agregadas e aproximadas pelos múltiplos dos tamanhos dos lotes, por exemplo, um pedido de 200 sacos de 25kg de determinado suplemento é equivalente a 2 bateladas.
- b) A unidade de suplementos estudada produz cerca de 200 produtos. Para diminuir o número de variáveis e restrições e tornar o modelo mais tratável computacionalmente, os produtos foram agregados em famílias. Os produtos têm duas características que formam as famílias comerciais. Uma se refere ao tipo de produto: concentrados, premixes, núcleos, promotores, minerais e sais minerais; e, outra característica que são os animais aos quais estes produtos se destinam: suínos, bovinos, eqüinos, aves de corte, aves de postura e peixes. A combinação destas linhas de produtos com os animais aos quais são destinados resultam nas famílias comerciais: premixes bovinos, premixes suínos, núcleos aves de corte, etc., formando um total de 37 famílias comerciais. Entretanto, dentro destas famílias existem produtos que pertencem a diferentes grupos de contaminação, ou seja, alguns produtos dentro da mesma família não podem ser produzidos, uns seguidos dos outros, porque têm em suas formulações ingredientes contaminantes. Existe um total de 51 grupos de contaminação definidos pelo departamento técnico. Dentro dos grupos de contaminação, observamos que existem produtos de diferentes famílias comerciais, e, ainda, que existem grupos que possuem as mesmas relações de precedência. Ou seja, têm o mesmo conjunto de produtos antes dos quais não devem ser produzidos, e também o mesmo conjunto de produtos depois dos quais não devem ser produzidos, sem que ocorra uma limpeza na linha. Sendo assim, os grupos de contaminação foram reagrupados em 26

famílias, considerando-se que em cada grupo só podem existir produtos do mesmo tipo (núcleos, premixes, minerais, etc.), pois os tempos de processamento variam de acordo com o tipo de produto (uma explicação mais detalhada sobre este plano de agregação encontra-se no apêndice A). Os termos família, produto e item, no modelo a seguir tem o mesmo significado.

- c) Quando não existe risco de contaminação residual, o tempo de preparação entre um lote e outro é muito pequeno, tanto entre produtos dentro da mesma família, quanto entre produtos de famílias diferentes. Além disso, quando agregamos os produtos em famílias, fica difícil considerar estes tempos. Portanto, por simplicidade, tempos de preparação relativamente pequenos (menos de 10 minutos) foram desprezados.

4.2 Abordagens GLSP

Baseando-se nos modelos apresentados no capítulo anterior, um modelo matemático que representa adequadamente o problema em questão é o GLSP-ST (equações (3.15) a (3.24)) proposto por Meyr (2000), que considera a perda de capacidade resultante dos tempos de preparação dependentes da seqüência.

Por outro lado, o modelo capacitado proposto por Hax e Candea (1984), também abordado no capítulo anterior (equações (3.8) a (3.14)), fornece uma boa representação das considerações acerca da utilização de horas extras para aumentar a capacidade produtiva, penalizando os custos de produção.

Desta forma, como em Toso (2003) e Toso e Morabito (2005), os modelos matemáticos propostos para o problema na unidade de suplementos da empresa estudada, consistem basicamente em uma combinação dos modelos acima citados, com pequenas adaptações adicionais.

4.2.1 GLSP Seqüências Dependentes

Primeiramente é formulado o modelo para a estratégia Seqüências Dependentes em que não se considera uma limpeza ao final de cada período, ou seja, pressupõe-se que não existe a limpeza semanal. Desta forma, além do modelo integrar as decisões de dimensionamento e o seqüenciamento dos lotes de produção, deve encontrar uma única seqüência para todos os períodos.

A seguir são identificados e analisados os parâmetros, variáveis, objetivos e restrições para o problema de dimensionamento e seqüenciamento de lotes na fábrica de suplementos para nutrição animal.

Os índices do problema são:

i, j famílias, $i, j = 1, \dots, N$

t período, $t = 1, \dots, T$

s subperíodo, $s = 1, \dots, S$

onde,

N número de famílias,

T total de períodos,

S total de subperíodos (contagem seqüencial independente de t).

O período t corresponde a uma semana no problema proposto, e é dividido em um número máximo fixo de subperíodos s . O número de subperíodos determina a quantidade de produtos diferentes (lotes) que podem ser produzidos por período. Para o estudo de caso em questão, consideramos que o número máximo de subperíodos dentro de t ($|S_t|$) é igual ao total de famílias existente (N), o que permite que em uma semana possam ser produzidas todas as famílias. Isso é possível na prática. Os comprimentos dos subperíodos s são variáveis de decisão expressas pelas quantidades produzidas em cada subperíodo, mais os tempos de preparação utilizados em s . Admite-se que não existe sobreposição entre os subperíodos e seus tamanhos são variáveis, podendo inclusive ter comprimento zero (sem nenhuma produção). Mesmo quando ocorre de um subperíodo ter comprimento zero, o estado de preparação é conservado, isto é, se depois de um subperíodo sem produção, ocorrer a produção do mesmo item, um novo tempo de preparação não é incorrido.

Uma seqüência de subperíodos consecutivos em que um mesmo item é produzido define um lote, e a quantidade produzida durante estes subperíodos define o tamanho do lote. Observe que um lote pode continuar sobre diversos subperíodos e períodos, e é independente da estrutura de tempo discreto dos períodos adotada. Os subperíodos fornecem o número, o tamanho e a seqüência dos lotes (Meyr, 2000).

Para formular o modelo vamos considerar os seguintes parâmetros:

S_t grupo de subperíodos s ao longo do período t S_t é um subconjunto de $\{1, 2, \dots, S\}$

C_t capacidade de tempo disponível no período t

p_i consumo de tempo necessário para produzir uma unidade da família i

l_{m_i} lote mínimo da família i (unidades)

- h_i custos de manter uma unidade de estoque da família i por um período t .
 co_t custo unitário de hora extra no período t
 st_{ji} tempo de preparação para mudar da família j para a família i
 d_{it} demanda da família i no período t (unidades)
 I_{i0}^+, I_{i0}^- estoque/ *backlog* inicial da família i no começo do horizonte de planejamento (unidades)
 x_{i0} indica se a máquina está preparada para produzir a família i no começo do horizonte de planejamento ($x_{i0} = 1$) ou não ($x_{i0} = 0$)
 u_t limite máximo de horas extras permitido no período t

As variáveis de decisão do modelo são:

- I_{it}^+, I_{it}^- estoque/ *backlog* da família i no fim do período t (unidades)
 q_{is} tamanho do lote da família i produzido no subperíodo s (unidades). O tamanho do lote é múltiplo do número de bateladas, e, portanto deve ser uma variável inteira Note que esta é uma diferença importante em relação aos modelos do capítulo 3.
 x_{is} indica se a linha está preparada (limpa), e pode produzir a família i no subperíodo s ($x_{is} = 1$) ou não ($x_{is} = 0$)
 y_{jis} indica se ocorre troca das famílias j para i no subperíodo s ($y_{jis}=1$) ou não ($y_{jis}=0$)
 O_t quantidade de horas extras utilizada no período t

FUNÇÃO OBJETIVO: A função objetivo expressa o critério de desempenho procurado pela empresa, que é minimizar o custo total, composto dos custos de estocagem e custos de horas extras. Desta forma, temos a seguinte função objetivo:

$$\min \sum_{i=1}^N \sum_{t=1}^T h_{it} (I_{it}^+ + M I_{it}^-) + \sum co_t O_t \quad (4.1)$$

onde M representa um número suficientemente grande para que o não atendimento da demanda no prazo seja inviável.

É importante observar que esta função objetivo é diferente das funções objetivo dos dois modelos apresentados no capítulo 3, dos quais este foi adaptado: Meyr (2000) e Hax e Candea (1984) (veja as equações (3.15) e (3.8), respectivamente). Note que, diferentemente das funções objetivo dos modelos originais ((3-8) e (3-15)), esta não considera os custos de preparação. Para o estudo de caso em questão, se existe capacidade disponível, é possível realizar preparações adicionais sem necessariamente incorrer em custos adicionais relevantes.

Isto ocorre porque as preparações consomem basicamente apenas o recurso mão de obra, e o nível de força de trabalho é fixo de um período para outro. Desta forma, basta considerar que os tempos de preparação consomem a capacidade disponível. Entretanto, do ponto de vista do planejamento, uma solução com um programa de produção mais bem seqüenciado, com menos preparações deve ser preferível. Para diferenciar estas soluções sem interferir no *trade-off* dos custos, as variáveis de preparação são incluídas na função objetivo com uma pequena

penalização:
$$\left(\alpha \sum_{j=li=1}^N \sum_{s=1}^S st_{ji} y_{jis} \right) \quad (4.1a)$$

onde α representa um número suficientemente pequeno, de forma que o valor da penalização dos tempos de preparação na função objetivo seja irrelevante em relação aos outros termos da função objetivo. Note que as variáveis que representam as trocas (y_{jis}) são multiplicadas pelos tempos de preparação (st_{ji}). Desta forma, são penalizadas na função objetivo apenas as trocas que envolvem a limpeza da linha.

A inclusão da possibilidade de estoque negativo (I_{it}^-) torna o modelo mais flexível. Para o estudo de caso em questão, devido às pressões de mercado, esta possibilidade é bem indesejável. Desta forma, isto será fortemente desencorajado por meio da escolha do valor para o fator de penalização (M).

RESTRICÇÕES:

a) Balanceamento de estoque – a quantidade de produtos em estoque, menos a quantidade de pedidos pendentes no fim da semana, deve ser igual a quantidade de estoque, menos a quantidade de pedidos pendentes em mãos no início da semana (ou seja, do fim da semana anterior), mais a somatória de todas as quantidades de todos os produtos produzidos nos subperíodos s , menos os pedidos demandados na semana (figura 4.2), ou seja:

$$I_{it}^+ - I_{it}^- = I_{i,t-1}^+ - I_{i,t-1}^- + \sum_{s \in S_t} q_{is} - d_{it} \quad i = 1, \dots, N \quad t = 1, \dots, T \quad (4.2)$$




Figura 4.2 Fluxo de materiais para o balanceamento de estoque (4.2).

Esta restrição é semelhante a (3.16), incluindo a possibilidade de pedidos pendentes. Note que é diferente da equação (3.9) porque, como o período t foi subdividido, a quantidade produzida em cada período corresponde à somatória de todas as quantidades produzidas em todos os subperíodos s dentro do período t .

b) Capacidade – a capacidade produtiva disponível é considerada em termos de tempo, e corresponde aos turnos trabalhados dentro da semana, mais as possíveis horas extras necessárias para atender a demanda do período. Os tempos de *setup* referentes as trocas de produtos acarretam em perda da capacidade. Desta forma, temos que a somatória dos tempos necessários para a produção de todos os produtos nos subperíodos, mais o tempo necessário para a preparação da linha toda vez que ocorre uma troca de produto, deve ser inferior à quantidade disponível de tempo na semana (horas normais C_t), mais o número de horas extras necessárias (O_t) (figura 4.3).

$$\sum_{i=1}^N \sum_{s \in S_t} p_i q_{is} + \sum_{i=1}^N \sum_{j=1}^N \sum_{s \in S_t} st_{ji} y_{jis} \leq C_t + O_t \quad t = 1, \dots, T \quad (4.3)$$




Figura 4.3 Esquema para ilustrar a capacidade produtiva (restrição 4.3).

Note que se a família i for produzida no subperíodo s , então o tamanho deste subperíodo é $p_i q_{is}$, mais um eventual tempo de preparação $st_{ji} y_{jis}$ (figura 4.3).

Tanto no modelo proposto por Meyr (2000) quanto no modelo proposto por Hax e Candea (1984), os tempos de preparação são incluídos, diminuindo a capacidade disponível total. No entanto, no primeiro a capacidade se limita à quantidade do período C_t , não considerando a possibilidade do uso de horas extras para ampliar a capacidade total ($C_t + O_t$). Por outro lado, o segundo não considera que os tempos de preparação sejam dependentes da seqüência produtiva. Sendo assim, esta restrição é uma combinação e adaptação das restrições (3.10) e (3.17).

c) Estado de preparação – a produção de um item só pode ocorrer se a máquina estiver preparada (limpa) para aquele item e, um e somente um estado de preparação

pode ocorrer em cada subperíodo. Sendo assim, a combinação das duas equações abaixo garantem esta condição.

$$p_i q_{is} \leq (C_t + u_t) x_{is} \quad i = 1, \dots, N \quad t = 1, \dots, T \quad s \in S_t \quad (4.4)$$

$$\sum_{i=1}^N x_{is} = 1 \quad s = 1, \dots, S \quad (4.5)$$

A restrição (4.4) garante que só ocorre a produção de um item i em um subperíodo s pertencente ao respectivo período t , se a variável de preparação x_{is} for igual a 1, ou seja, a linha de produção não está contaminada. Esta restrição corresponde à restrição (3.18), com a diferença de que a capacidade C_t pode ser ampliada para, no máximo, $(C_t + u_t)$. A restrição (4.5) é igual a (3.20) e garante que a linha só pode estar preparada para uma única família de produtos por subperíodo.

d) Lote mínimo – não devem ocorrer mudanças no estado de preparação sem que ocorra uma mudança de produtos, pois isto levaria a uma avaliação errada dos tempos de preparação. Também devem ser introduzidas, por razões técnicas (conforme discussão no final do capítulo 2), quantidades de lote mínimo.

$$q_{is} \geq lm_i (x_{is} - x_{i,s-1}) \quad i = 1, \dots, N \quad s = 1, \dots, S \quad (4.6)$$

Esta restrição é de fundamental importância para a modelagem do estudo de caso, pois a matriz de tempos de preparação não satisfaz a desigualdade triangular, assim como a matriz de custos de preparação apresentada no capítulo anterior. Ou seja,

$$st_{jk} + st_{ki} \geq st_{ji} \quad \forall i, j, k = 1, \dots, N \quad \text{nem sempre é válida.}$$

Para um melhor entendimento desta questão, considere os seguintes produtos i , j e k , conforme a figura 4.4. Suponha que no subperíodo $(s-1)$ ocorra a produção do produto j (fig. 4.4-a), a linha fica com resíduos de j que são contaminantes para o produto i , sendo necessário fazer uma limpeza na linha para viabilizar a produção de i em seguida no subperíodo s . Se ao invés disto produzirmos no subperíodo s o produto k , que não é contaminado pelos resíduos de j e não contamina i , este produto ‘limpa’ a linha e teremos um tempo de preparação (st_{jk}) de j para k (fig. 4.4-b). Para produzir i depois de k no subperíodo $(s+1)$, temos um tempo de preparação (st_{ki}) (fig. 4.4-c). Existem exemplos na indústria de rações em que o tempo total de preparação da seqüência $j-k-i$ é menor do que o tempo de preparação da seqüência $j-i$, onde é necessário fazer a limpeza da linha (st_{ji}) .




Figura 4.4 Exemplo ilustrativo que viola a desigualdade triangular.

Sem a restrição (4.6) de lote mínimo, o modelo pode gerar uma preparação para o item k , produzindo uma quantidade q_{ks} igual a zero no período s , e então no período $(s+1)$ produzir i . Adiante é apresentado um exemplo para ilustrar e analisar melhor esta questão.

e) Relação entre os estados de preparação e os indicadores de mudança- Toda vez que há uma mudança na linha de produção de um produto i para um produto j , deve haver uma mudança no estado de preparação da linha. A restrição abaixo relaciona estes indicadores:

$$y_{jis} \geq x_{j,s-1} + x_{is} - 1 \quad i, j = 1, \dots, N \quad s = 1, \dots, S \quad (4.7)$$

Estas inequações são equivalentes às inequações (3.21) do modelo GLSP-ST apresentado no capítulo anterior. Note que se $x_{j,s-1}=1$ e $x_{is}=1$, então (4.7) garante que $y_{jis} \geq 1$.

f) Variável do estado de preparação deve ser binária – A variável x_{is} que representa o estado de preparação da linha deve indicar somente duas situações: a linha está preparada para a produção do item i ou não, portanto, assim como na restrição (3.22), x_{is} ser uma variável binária:

$$x_{is} \in \{0,1\} \quad i = 1, \dots, N \quad s = 1, \dots, S \quad (4.8)$$

g) Restrições de não negatividade e integralidade – As variáveis que representam o estoque de produtos (I_{it}), a quantidade a ser produzida (q_{is}), e os indicadores de mudança (y_{jis}) devem ser não negativas:

$$I_{it}^+, I_{it}^-, q_{is}, y_{jis} \geq 0 \text{ e } q_{is} \text{ inteiro} \quad j = 1, \dots, N; s = 1, \dots, S; t = 1, \dots, T \quad (4.9)$$

As variáveis que representam os níveis de estoques (positivos e pendentes) do produto i no período t devem ser positivas ou nulas. Diferentemente do modelo de Meyr (2000), a quantidade a ser produzida do produto i no subperíodo s (q_{is}), além de ser não negativa, deve ser uma variável inteira, pois o problema de dimensionamento de lotes na fábrica de suplementos é um problema discreto. Ou seja, é inviável tanto técnica quanto economicamente produzir menos de uma batelada. As razões técnicas se referem ao fato de que, para se obter uma boa homogeneidade da mistura, é necessária uma quantidade de produto correspondente a pelo menos à metade da capacidade volumétrica do misturador. Além disso, a formulação impressa nas ordens de fabricação é balanceada por batelada, e dividir as quantidades durante a fase operacional aumenta a probabilidade de erros. As razões econômicas são óbvias, uma vez que os custos de produção de uma ou de uma fração de batelada são aproximadamente os mesmos. Alguns produtos customizados, cujas quantidades demandadas são menores que uma batelada, são produzidos pela unidade de microingredientes.

Observe nas restrições (4.9) que, como no modelo apresentado por Meyr (2000), a variável y_{jis} é considerada não negativa. A otimalidade do modelo não é afetada pela relaxação da condição de valores binários para as variáveis (y_{jis}). Isto pode ser explicado pelo seguinte argumento: dada uma solução ótima com valores y_{jis} fracionais, sempre é possível encontrar uma solução alternativa, ou seja, com o mesmo valor da função objetivo, fixando as variáveis y_{jis} em 0, quando $0 < y_{jis} < 1$, e em 1, quando $y_{jis} > 1$.

h) Limites de horas extras – As horas extras são regulamentadas pelas leis trabalhistas e podem ser negociadas pelos sindicatos de cada indústria. No estudo de caso em questão, além deste limite, existem outros relacionados às metas de planejamento estratégico da empresa. Para a modelagem do problema vamos admitir como limite (u_t) o máximo permitido por lei, pois são penalizadas na função objetivo, devendo ser minimizadas. O limite mínimo é zero, pois não existe hora extra negativa.

$$0 \leq O_t \leq u_t \quad t = 1, \dots, T \quad (4.10)$$

Esta equação corresponde à equação (3.12) do modelo proposto por Hax e Candea (1984).

Por conveniência, reproduzimos a seguir todas as equações (4.1) – (4.10) do modelo de dimensionamento e sequenciamento de lotes considerando a estratégia seqüências dependentes, para a unidade de suplementos:

GLSP SEQÜÊNCIAS DEPENDENTES

$$\min \sum_{i=1}^N \sum_{t=1}^T h_{it} (I_{it}^+ + M I_{it}^-) + \sum c_{ot} O_t \quad (4.1)$$

sujeito a

$$I_{it}^+ - I_{it}^- = I_{i,t-1}^+ - I_{i,t-1}^- + \sum_{s \in S_t} q_{is} - d_{it} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.2)$$

$$\sum_{i=1}^N \sum_{s \in S_t} p_i q_{is} + \sum_{i=1}^N \sum_{j=1}^N \sum_{s \in S_t} s^t y_{jis} \leq C_t + O_t \quad t = 1, \dots, T \quad (4.3)$$

$$p_i q_{is} \leq (C_t + u_t) x_{is} \quad i = 1, \dots, N; t = 1, \dots, T; s \in S_t \quad (4.4)$$

$$q_{is} \geq l m_i (x_{is} - x_{i,s-1}) \quad i = 1, \dots, N; s = 1, \dots, S \quad (4.5)$$

$$\sum_{i=1}^N x_{is} = 1 \quad s = 1, \dots, S \quad (4.6)$$

$$y_{jis} \geq x_{j,s-1} + x_{is} - 1 \quad i, j = 1, \dots, N; s = 1, \dots, S \quad (4.7)$$

$$x_{is} \in \{0,1\} \quad i = 1, \dots, N; s = 1, \dots, S \quad (4.8)$$

$$I_{it}^+, I_{it}^-, q_{is}, y_{jis} \geq 0 \quad q_{is} \text{ inteiro, } i, j = 1, \dots, N; t = 1, \dots, T; s = 1, \dots, S \quad (4.9)$$

$$0 \leq O_t \leq u_t \quad t = 1, \dots, T \quad (4.10)$$

O modelo foi definido considerando a produção de N produtos (famílias), em cada um dos T períodos e em um total S de subperíodos, envolvendo $[N(NS + 2S + T) + T]$ variáveis, das quais (NS) são binárias e (NS) são inteiras. Se a variável y_{jis} for modelada como binária, temos $[NS(N+1)]$ variáveis binárias. O total de restrições é $[N(NS + 2S + T) + S + 2T]$.

Cabe ressaltar que este modelo é similar ao modelo apresentado em Toso (2003) e Toso e Morabito (2005). As diferenças são: inclusão das variáveis de estoque negativo (I_{it}^-), o que torna o modelo mais flexível na medida em que contempla a alternativa de entregar pedidos atrasados mesmo com alta penalização; termo de penalização dos tempos de preparação (4.1a) considerados na função objetivo. Testes com dados reais apresentados nos trabalhos anteriores mostram que, embora este modelo seja difícil de resolver otimamente, é uma boa representação da situação real.

4.2.2 GLSP Seqüências Independentes

Uma outra abordagem para o problema é baseada na outra estratégia da empresa de fazer uma limpeza ao final de cada período (semana). Esta estratégia torna o seqüenciamento da produção independente entre períodos. Para modelar esta situação, basta dividir o conjunto de sub-períodos $\{1,2,\dots,S\}$ (definido para o modelo anterior) pelo número de períodos t , e redefinir as variáveis da seguinte forma:

- q_{ist} tamanho do lote da família i produzido no subperíodo s do período t .
- x_{ist} indica se a linha está preparada para produzir a família i no subperíodo s do período t ($x_{ist}=1$) ou não ($x_{ist}=0$)
- y_{jst} indica se ocorre troca das famílias j para i no subperíodo s do período t ($y_{jst}=1$) ou não ($y_{jst}=0$)

Desta forma, cada período t tem um conjunto S de sub-períodos, que são seqüenciados independentemente.

GLSP SEQÜÊNCIAS INDEPENDENTES:

$$\min \sum_{i=1}^N \sum_{t=1}^T h_{it} (I_{it}^+ + M I_{it}^-) + \sum c_{ot} O_t \quad (4.11)$$

sujeito a

$$I_{it}^+ - I_{it}^- = I_{i,t-1}^+ - I_{i,t-1}^- + \sum_{s=1}^S q_{ist} - d_{it} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.12)$$

$$\sum_{i=1}^N \sum_{s=1}^S p_i q_{ist} + \sum_{i=1}^N \sum_{j=1}^N \sum_{s=1}^S st_{ji} y_{jst} \leq C_t + O_t \quad t = 1, \dots, T \quad (4.13)$$

$$p_i q_{ist} \leq (C_t + u_t) x_{ist} \quad i = 1, \dots, N; t = 1, \dots, T; s = 1, \dots, S \quad (4.14)$$

$$q_{ist} \geq lm_i (x_{ist} - x_{i,s-1,t}) \quad i = 1, \dots, N; t = 1, \dots, T; s = 1, \dots, S \quad (4.15)$$

$$\sum_{i=1}^N x_{ist} = 1 \quad s = 1, \dots, S; t = 1, \dots, T \quad (4.16)$$

$$y_{jst} \geq x_{j,s-1,t} + x_{ist} - 1 \quad i, j = 1, \dots, N; t = 1, \dots, T; s = 1, \dots, S \quad (4.17)$$

$$x_{ist} \in \{0,1\} \quad i = 1, \dots, N; t = 1, \dots, T; s = 1, \dots, S \quad (4.18)$$

$$I_{it}^+, I_{it}^-, q_{ist}, y_{jst} \geq 0 \quad q_{ist} \text{ inteiro}, i, j = 1, \dots, N; t = 1, \dots, T; s = 1, \dots, S \quad (4.19)$$

$$0 \leq O_t \leq u_t \quad t = 1, \dots, T \quad (4.20)$$

Note que o número total de variáveis, o número de variáveis inteiras e binárias, e o número total de restrições não se alteram nesta abordagem. Cabe mencionar, que o termo de penalização (4.1a) foi incluído na função objetivo para realização dos experimentos computacionais.

Estas abordagens, GLSP Sequências Dependentes e GLSP Sequências Independentes, embora modeladas matematicamente de forma muito semelhante, interferem bastante no tempo de resolução computacional do modelo, conforme é mostrado adiante.

4.2.3 Métodos de Solução para os Modelos GLSP

Conforme discutido no capítulo anterior, a aplicação de métodos de solução exatos em problemas reais implica em tratar um grande número de variáveis e restrições. A aplicação destes modelos na unidade produtora de suplementos, objeto deste estudo de caso, considerando a programação da produção de 26 famílias ($N=26$ e $S=104$) durante um horizonte de planejamento de 4 semanas ($T=4$), resulta em um problema com 75928 restrições e 75920 variáveis. Experimentos com dados reais mostram que estes modelos são difíceis de resolver otimamente, mesmo utilizando muitas horas de processamento computacional.

Desta forma, neste trabalho são propostas abordagens heurísticas baseadas em programação matemática para resolver este modelo. Conforme discutido no capítulo anterior, a estratégia *Relax-and-Fix* consiste em resolver o problema de forma iterativa. O conjunto de variáveis inteiras e binárias é particionado em subconjuntos, cada um com um grupo reduzido de variáveis inteiras, cujo número é pequeno o bastante para obter rapidamente soluções ótimas MIP (Wolsey, 1998; Pochet e Wolsey, 2006). Desta forma, uma seqüência de MIPs parcialmente relaxados é resolvida. Conforme a série avança, cada grupo de variáveis inteiras é permanentemente fixado em seus valores da solução.

Para aplicar a estratégia *Relax-and-Fix* no modelo GLSP, são propostas duas estratégias de partição do conjunto de variáveis inteiras. A primeira estratégia consiste em dividir as variáveis inteiras e binárias em dois grupos: variáveis de dimensionamento de lotes e variáveis de preparação. Na segunda, as variáveis inteiras e binárias são divididas em períodos.

Relax-and-fix variáveis. As variáveis inteiras e binárias são divididas em dois grupos: as variáveis inteiras (q_{is}), que determinam o tamanho de lote para o produto i no sub-período s ; e, as variáveis binárias (x_{is}), que indicam se a linha está ou não preparada para o produto i no sub-período s . O primeiro passo da heurística *relax-and-fix* é resolver o problema relaxando a integralidade das variáveis do primeiro grupo (q_{is}). Desta forma, temos uma solução relaxada (q_{is}^1) e soluções inteiras (x_{is}^1). No segundo passo os valores encontrados para (x_{is}) são fixados ($x_{is} = x_{is}^1$), a condição de integralidade de (q_{is}) é retomada e o modelo é resolvido novamente. Se a solução do segundo passo (x_{is}^1, q_{is}^2) for factível, então esta é a solução da heurística.

Nesta estratégia o seqüenciamento dos lotes é definido no primeiro passo. Note que, mesmo relaxando a integralidade de (q_{is}), este problema é difícil de ser resolvido otimamente. Portanto, a estratégia adotada neste caso foi impor um limite de tempo, obtendo uma solução heurística MIP truncado (Pochet e Wolsey, 2006) para ser usada no segundo passo.

Relax-and-fix períodos. O conjunto das variáveis inteiras e binárias é particionado por períodos. Em um primeiro passo, somente as variáveis do primeiro período são mantidas inteiras ou binárias, as variáveis dos demais períodos são relaxadas, e o modelo GLSP é resolvido. Os valores obtidos para as variáveis do primeiro período são fixados, as condições de integralidade são retomadas para as variáveis do segundo período, e o modelo GLSP é novamente resolvido. Este procedimento é repetido até que todos os períodos tenham sido resolvidos. Este procedimento pode ser feito do primeiro para o último período (*forward*) ou do último para o primeiro (*backward*).

Quando esta estratégia é usada do primeiro para o último período, comporta-se como uma heurística gulosa, pois como as variáveis dos períodos adiante estão relaxadas, podem não ser realizadas antecipações de estoque.

4.3 Abordagens ATSP

Inspirando-se nos trabalhos de Fleischmann (1994), Salomon *et al.* (1997), Clark (2000) e Pochet e Wolsey (2006), propomos uma abordagem alternativa para o problema de dimensionamento e seqüenciamento de lotes de produção na indústria de suplementos, que consiste em modelar as decisões de seqüenciamento como um problema do caixeiro viajante assimétrico (ATSP).

Assim como na proposta de Clark (2000) (seção 3.3.3), a estratégia é usar no modelo a formulação do ATSP para o seqüenciamento, no entanto, sem decompor o modelo em dois modelos distintos. Para reformular o seqüenciamento de lotes do modelo GLSP usando a formulação ATSP, mantemos as mesmas considerações anteriores, mais a consideração adicional de que cada família é produzida uma única vez em cada período.

Esta consideração é a principal diferença entre os modelos GLSP e ATSP. Na verdade, podemos dizer que esta é uma deficiência do modelo ATSP em relação ao GLSP. Como a desigualdade triangular não é válida, no modelo GLSP um mesmo produto pode ser usado como ‘limpante’ mais de uma vez no mesmo período. A figura 4.5 mostra um exemplo ilustrativo de uma possível seqüência GLSP e uma ATSP. Neste exemplo, o produto 2 funciona como ‘limpante’, na seqüência GLSP este produto é produzido duas vezes no período, economizando uma preparação.




Figura 4.5 Exemplo ilustrativo de seqüência GLSP e ATSP.

Conforme mencionado no capítulo 3, modelos e métodos para o TSP são amplamente estudados na literatura. Desta forma, existem diversas formulações para os modelos TSP, como a formulação clássica de Dantzig, Fulkerson e Johnson (DFJ), ou a formulação proposta por Miller, Tucker e Zemlin (MTZ). Estas formulações também são analisadas em Laporte (1992) e Pataki (2003). Orman e Willians (2004) fazem um estudo comparativo de oito formulações diferentes, que são divididas em: formulações seqüenciais; baseadas em fluxo (*flow based*); e, com etapas de tempo (*time staged*). Para modelar as restrições de seqüenciamento de lotes como ATSP, usamos a formulação clássica DFJ.

Da mesma forma que na abordagem GLSP, são apresentados dois modelos baseados nas estratégias da empresa para os diferentes ciclos sazonais: seqüências dependentes e seqüências independentes.

4.3.1 ATSP Seqüências Independentes

Neste modelo pressupõe-se que é feita uma limpeza ao final de cada período (por exemplo, no final de cada semana). Desta forma, uma nova seqüência começa sem nenhuma relação com a anterior, do ponto de vista do seqüenciamento. Conforme discutido anteriormente, esta estratégia é adotada na prática da empresa estudada em meses com folga de capacidade, em que o tempo utilizado para limpeza não é necessário para produção. Assim, o dimensionamento e o seqüenciamento são feitos de forma simultânea para todo horizonte de planejamento, mas as seqüências em cada período são independentes entre si.

Podemos definir o seqüenciamento de lotes para a abordagem Seqüências Independentes da seguinte forma: para cada período t , temos um grafo $G = (V, A)$, onde V corresponde a um conjunto de (i) a serem produzidos em t (ou seja, é um subconjunto do número total de produtos, N , para os quais $q_{it} > 0$), e os arcos A correspondem às possíveis trocas entre cada par de produtos (y_{ji}), o problema consiste em encontrar um caminho Hamiltoniano saindo de uma origem e passando por todos os vértices. O custo associado ao grafo st_{ji} corresponde ao tempo de preparação necessário para ir de j para i .

Desta forma, para formular o seqüenciamento de lotes, é preciso determinar um ponto de partida, ou seja, um produto para o qual a linha já esteja preparada no começo de cada período t . Como no caso da indústria de nutrição animal, linha preparada significa linha limpa, ou seja, o produto inicial pode ser qualquer um. Alguns testes preliminares mostraram que a escolha de um produto inicial tem grande impacto no resultado do modelo. Desta forma, foi usado o artifício de um produto fantasma i_0 , a partir da qual o tempo de preparação é zero para qualquer outro produto j ($st_{i_0j} = 0$) (Clark 2000). Da mesma maneira, para impedir que ocorram preparações a partir de um produto j para o produto fantasma i_0 , impõe-se que $st_{ji_0} = \infty$. Para não interferir nos resultados do problema, este produto i_0 também tem tempo de produção e demanda zero, ou seja, $p_{i_0t} = 0$ e $d_{i_0t} = 0 \quad \forall t$.

Os índices para formular os modelos são:

i famílias de produtos, $i = 1, \dots, N$
 t períodos (e.g., semanas), $t = 1, \dots, T$

onde,

N número de famílias

T número de períodos do horizonte de planejamento

Os parâmetros dos modelos são:

C_t	tempo disponível (capacidade) no período t
p_i	tempo necessário para produzir uma unidade da família i
lm_i	tamanho mínimo de um lote da família i (unidades em bateladas)
h_i	custo de manter uma unidade de estoque da família i por um período t .
co_t	custo unitário de hora extra no período t
st_{ji}	tempo de preparação para mudar da família j para a família i (com $st_{ii}=0$)
d_{it}	demanda da família i no período t (unidades)
I_{i0}^+, I_{i0}^-	estoque/ <i>backlog</i> inicial da família i no começo do horizonte de planejamento (unidades)
u_t	limite máximo de horas extras permitidas no período t
M	penalização por pedidos pendentes

As variáveis de decisão dos modelos são:

I_{it}^+	quantidade em estoque da família i no fim do período t .
I_{it}^-	quantidade pendente do produto i no fim do período t .
q_{it}	tamanho do lote da família i produzido no período t . O tamanho do lote é múltiplo do número de bateladas, e, portanto, deve ser uma variável inteira.
y_{jit}	indica se ocorre troca das famílias j para i no período t ($y_{jit}=1$) ou não ($y_{jit}=0$)
O_t	quantidade de horas extras utilizadas no período t

FUNÇÃO OBJETIVO: A função objetivo (4.21) é idêntica a dos modelos GLSP, refere-se aos objetivos da empresa, e consiste em minimizar as penalidades por atraso, os custos de estocagem e de horas extras:

$$\sum_{i=1}^N \sum_{t=1}^T h_{it} (I_{it}^+ + M I_{it}^-) + \sum co_t O_t \quad (4.21)$$

RESTRICÇÕES:

a) Balanceamento de estoque – são restrições de balanceamento de estoques, atrasos, produção e demanda sobre semanas consecutivas. Note que, diferentemente da abordagem GLSP, a quantidade produzida é definida em função dos índices (i,t) como no modelo CLSP.

$$I_{it}^+ - I_{it}^- = I_{i,t-1}^+ - I_{i,t-1}^- + q_{it} - d_{it} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.22)$$

b) Capacidade – estas restrições consideram os tempos de preparação, bem como os tempos de produção atuais, e a possibilidade de uma quantidade limitada de horas extras.

$$\sum_{i=1}^N p_i q_{it} + \sum_{j=1}^N \sum_{l=1}^N st_{ji} y_{jlt} \leq C_t + O_t \quad t = 1, \dots, T \quad (4.23)$$

Note que a primeira preparação (*setup*) ocorre a partir do item fantasma i_0 e então $st_{i_0j} = 0$ em todo período t .

c) Estado de Preparação – estas restrições garantem que a produção de uma família pode ocorrer em um período somente se a linha está preparada para aquele produto naquele período. Diferentemente do modelo GLSP, onde o estado de preparação da máquina é determinado pela variável x_{is} , este modelo considera que, se a linha está preparada, então

$$\sum_{j=1}^N y_{jlt} = 1.$$

$$p_i q_{it} \leq (C_t + u_t) \sum_{j=1}^N y_{jlt} \quad i = 1, \dots, N \quad i \neq i_0; t = 1, \dots, T \quad (4.24)$$

d) Lote Mínimo - estas restrições forçam a produção de um lote mínimo sempre que ocorrer uma preparação, e são necessárias, porque conforme já apresentado, os tempos de preparação nem sempre satisfazem a desigualdade triangular.

$$q_{it} \geq lm_i \sum_{j=1}^N y_{jlt} \quad i = 1, \dots, N \quad i \neq i_0; t = 1, \dots, T \quad (4.25)$$

Note que, como a desigualdade triangular não é válida, em certas circunstâncias, uma solução ótima poderia ter mais do que um lote do produto ‘limpante’ no mesmo período (conforme ilustrado na figura 4.5). Um modelo ATSP adequado para permitir a utilização do mesmo produto como ‘limpante’ mais de uma vez no período não é desenvolvido neste trabalho.

e) Proibição de preparação para mesma família – a condição de que não é necessária preparação entre produtos da mesma família, é garantida por estas restrições:

$$y_{iit} = 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.26)$$

f) Restrições ATSP - os próximos quatro conjuntos de equações são restrições TSP, que fazem o seqüenciamento entre os produtos. Diferentemente da formulação DFJ usada no

modelo de Clark (2000), onde as restrições (3.43)-(3.46) possuem relação de igualdade, as restrições de seqüenciamento neste modelo são expressas por relações de desigualdade. Isto porque, neste problema combinado de dimensionamento e seqüenciamento, não são ‘todos’ os produtos que devem ser seqüenciados em cada período, mas apenas os produtos que serão produzidos no período ($q_{it} > 0$).

Pelas restrições (4.27), somente pode chegar um arco em um nó i qualquer, se existir um arco saindo de i_0 . Analogamente, estas restrições permitem uma troca de um produto k para um produto i , qualquer, somente se houve uma troca de i_0 para um produto j qualquer. Isto garante que i_0 esteja no começo da seqüência em cada período (figura 4.6a).

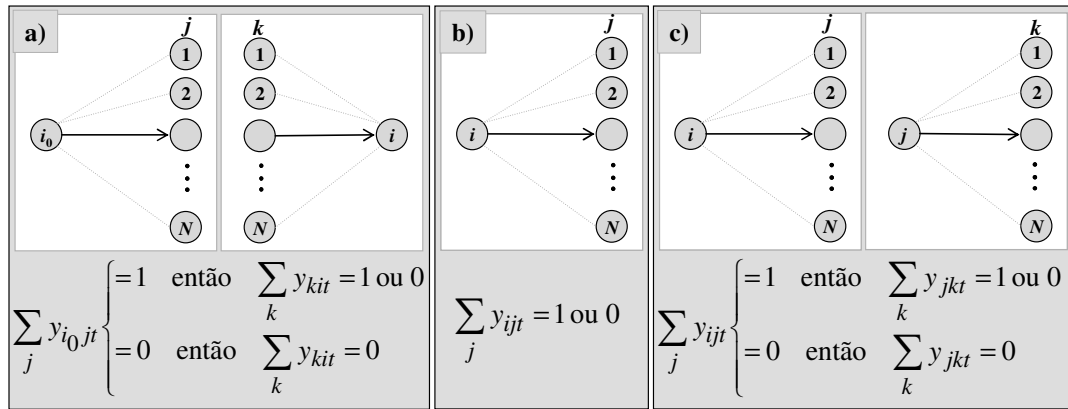


Figura 4.6 Ilustração das restrições ATSP: (a) 4.27; (b) 4.28; e (c) 4.29.

$$\sum_{j=1}^N y_{i_0 j t} \geq \sum_{k=1}^N y_{k i t} \quad i = 1, \dots, N; t = 1, \dots, T; i \neq i_0 \quad (4.27)$$

As restrições (4.28) proibem mais de uma preparação a partir de uma família i , o que significa que em cada período só pode ser produzido um único lote de cada família (figura 4.6b).

$$\sum_{j=1}^N y_{i j t} \leq 1 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.28)$$

As restrições (4.29) permitem que exista um arco saindo de um nó j somente se existir um arco chegando em j . Ou seja, uma preparação a partir de uma família j (diferente de i_0) somente pode ocorrer se houve uma preparação para esta família j .

$$\sum_{i=1}^N y_{i j t} \geq \sum_{k=1}^N y_{j k t} \quad j = 1, \dots, N; t = 1, \dots, T; j \neq i_0 \quad (4.29)$$

O seqüenciamento a partir das restrições (3.27)-(3.29) pode gerar sub-rotas desconexas, conforme figura 4.7. Desta forma, são necessárias as restrições (4.30), que são restrições clássicas de proibição de sub-rotas (Lawler *et al.*, 1985; Laporte, 1992; Carpaneto *et al.*, 1995; Gutin *et al.*, 2002; Pataki, 2003; Orman e Williams, 2004; Arenales, *et al.*, 2007).

$$\sum_{i,j \in S_r} y_{ijt} \leq |S_r| - 1 \quad t = 1, \dots, T; S_r \subset PR; 2 \leq |S_r| \leq N - 2 \quad (4.30)$$

onde, $|S_r|$ corresponde a cardinalidade de qualquer sub-rotas S_r formada, e PR é o conjunto de todos os produtos $PR = \{1, 2, \dots, N\}$, no caso do exemplo ilustrado na figura 4.7 temos $N=7$.




Figura 4.7 Ilustração das sub-rotas. Fonte: Arenales *et al.* 2007.

De acordo com Pataki (2003) e Orman e Williams (2004), esta formulação de sub-rotas é adequada para problemas razoavelmente grandes, pois sua relaxação linear é mais forte que a de outras formulações da literatura.

g) Restrições de limite de horas extras – como nos modelos GLSP a disponibilidade de horas extras é limitada pelas restrições (4.31).

$$0 \leq O_t \leq u_t \quad t = 1, \dots, T \quad (4.31)$$

h) Restrições de não negatividade e integralidade - as restrições (4.32), (4.33) e (4.34) são restrições de não negatividade e integralidade das variáveis. As restrições (4.32) proíbem que as variáveis de estoque e atraso sejam negativas:

$$I_{it}^+, I_{it}^- \geq 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.32)$$

$$y_{ijt} = 0 \text{ ou } 1 \quad i, j = 1, \dots, N; t = 1, \dots, T \quad (4.33)$$

$$q_{it} \geq 0 \text{ e inteiro} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.34)$$

Conforme discutido acima, dado que os tempos de preparação de algumas famílias de produtos ‘limpantes’ desobedecem a desigualdade triangular, a formulação acima

não garante produzir uma solução ótima para o problema. Ou seja, pode ocorrer uma situação em que seja mais barato produzir mais de um lote de um mesmo produto para limpar a linha (figura 4.5).

Vale ressaltar que, embora seja grande o número de restrições de proibição de sub-rotas, a grande maioria não irá comprometer a solução ótima do modelo. Desta forma, estas restrições são impostas apenas para aquelas sub-rotas que ocorrerem, resolvendo-se o seqüenciamento como uma série de problemas tipo designação (conforme mostrado adiante). Dado que $st_{i,i_0} = \infty \forall i$, as restrições (4.35) abaixo são redundantes, mas podem ser adicionadas no modelo para tentar acelerar a convergência do método de solução. Elas garantem que não há preparação para a família fantasma i_0 , já preparada no começo de cada período:

$$y_{i,i_0t} = 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.35)$$

Por conveniência, reproduzimos as equações (4.21)-(4.35) do modelo denominado ATSP Seqüências Independentes.

ATSP SEQÜÊNCIAS INDEPENDENTES

$$\min \sum_{i=1}^N \sum_{t=1}^T h_{it} (I_{it}^+ + M I_{it}^-) + \sum co_t O_t \quad (4.21)$$

sujeito a

$$I_{it}^+ - I_{it}^- = I_{i,t-1}^+ - I_{i,t-1}^- + q_{it} - d_{it} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.22)$$

$$\sum_{i=1}^N p_i q_{it} + \sum_{j=1}^N \sum_{i=1}^N st_{ji} y_{jit} \leq C_t + O_t \quad t = 1, \dots, T \quad (4.23)$$

$$p_i q_{it} \leq (C_t + u_t) \sum_{j=1}^N y_{jit} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.24)$$

$$q_{it} \geq lm_i \sum_{j=1}^N y_{jit} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.25)$$

$$y_{iit} = 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.26)$$

$$\sum_{j=1}^N y_{i_0jt} \geq \sum_{k=1}^N y_{kit} \quad i = 1, \dots, N; t = 1, \dots, T; i \neq i_0 \quad (4.27)$$

$$\sum_{j=1}^N y_{ijt} \leq 1 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.28)$$

$$\sum_{i=1}^N y_{ijt} \geq \sum_{k=1}^N y_{jkt} \quad j = 1, \dots, N; t = 1, \dots, T \quad j \neq i_0 \quad (4.29)$$

$$\sum_{i, j \in Sr} y_{ijt} \leq |Sr| - 1 \quad \forall t, Sr \subset PR, 2 \leq |Sr| \leq N - 2 \quad (4.30)$$

$$0 \leq O_t \leq u_t \quad t = 1, \dots, T \quad (4.31)$$

$$I_{it}^+, I_{it}^-, \geq 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.32)$$

$$y_{ijt} = 0 \text{ ou } 1 \quad i, j = 1, \dots, N; t = 1, \dots, T \quad (4.33)$$

$$q_{it} \geq 0 \text{ e inteiro} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.34)$$

$$y_{i, i_0 t} = 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.35)$$

4.3.2 ATSP Seqüências Dependentes

Da mesma forma que no modelo GLSP Seqüências Dependentes, o modelo ATSP Seqüências Dependentes considera que não existe limpeza no final de cada período. Além do dimensionamento e o seqüenciamento dos lotes serem integrados, deve ser encontrada uma única seqüência para todos os períodos. Esta pressuposição torna o problema mais difícil, uma vez que no início de cada período t o modelo deve ‘guardar’ o estado de preparação da linha no final do período anterior ($t-1$). No modelo anterior, este estado de preparação no começo de cada período era tratado como um parâmetro (o produto fantasma i_0). Agora, este estado de preparação deve ser tratado como uma variável.

O seqüenciamento de lotes para a abordagem Seqüências Dependentes pode ser definido da seguinte forma: considerando um grafo $G = (V, A)$, V corresponde a um conjunto de produtos (i) a serem produzidos no período t (ou seja, é um subconjunto do número total de produtos, N , para os quais $q_{it} > 0$), e os arcos A correspondem às possíveis trocas entre cada par de produtos (y_{ji}), o problema consiste em encontrar um caminho Hamiltoniano saindo de uma origem e passando por todos os vértices. Diferentemente da abordagem seqüências Independentes, onde temos um grafo para cada período, nesta abordagem temos um único grafo para todos os períodos.

Para formular o modelo, é necessária a definição de nova variável e parâmetro:

- z_{it} variável que indica se linha está preparada para a família i no começo do período t ($z_{it}=1$), ou não ($z_{it}=0$). Ou seja, indica se a família i foi o último produto produzido em $(t-1)$.
- z_{i1} produto para o qual a linha está preparada no começo do horizonte de planejamento ($t=1$).

A função objetivo (4.21) e as restrições (4.22), (4.23), (4.26) e (4.30)-(4.34) fazem parte do modelo, mas para simplificar a apresentação dos modelos e posterior análise de seus resultados, a seguir estas equações são re-numeradas para (4.36), (4.37), (4.38), (4.39), (4.40)-(4.44), respectivamente. Entretanto, as demais restrições anteriores devem ser modificadas ou complementadas para formular a dependência da seqüência entre os períodos, ou seja, o ‘*carryover*’ de um estado de preparação do fim de um período para o começo do próximo, conforme figura 5.8. A linha de produção somente pode estar preparada para uma única família no começo do período; isto é garantido pela seguinte restrição:

$$\sum_{i=1}^N z_{it} = 1 \quad t = 2, \dots, T \quad (4.45)$$

Observe que a restrição (4.45) somente é válida a partir do segundo período, pois no primeiro período a configuração da linha é conhecida; logo, z_{i1} é um parâmetro (figura 4.8). As restrições (4.24) são substituídas pelas restrições (4.46), ainda garantindo que a produção de uma família pode ocorrer em um período somente se a linha está preparada adequadamente. Note que as restrições (4.46) permitem a produção da família que já esteja preparada no começo do período t .

$$p_i q_{it} \leq (C_t + u_t) \left(z_{it} + \sum_{j=1}^N y_{jit} \right) \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.46)$$




Figura 4.8 Ilustração do seqüenciamento gerado pelas restrições (4.45)-(4.52).

As restrições (4.25), que forçam a produção de um lote mínimo, não devem ser consideradas para o produto para o qual a linha já está preparada no começo de um período, pois no período anterior ($t-1$) ocorre uma preparação para este produto e, conseqüentemente, a produção do lote mínimo. Desta forma, as restrições (4.25) precisam ser substituídas pelas restrições (4.47):

$$q_{it} \geq lm_i \left(\sum_{j=1}^N y_{jit} - z_{it} \right) \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.47)$$

As restrições (4.27) são substituídas pelas restrições (4.48), permitindo que um produto j entre na seqüência somente se existir uma preparação depois de j , ou se j é o produto para a qual a linha está preparada no começo do próximo período:

$$\sum_{i=1}^N y_{ijt} \leq \sum_{k=1}^N y_{jkt} + z_{j,t+1} \quad j = 1, \dots, N; t = 1, \dots, T-1 \quad (4.48)$$

As restrições (4.28) são substituídas pelas restrições (4.49), permitindo que um produto k entre na seqüência depois de j somente se houve uma preparação para j , ou se a linha já estava preparada para o produto j no começo do período:

$$z_{jt} + \sum_{i=1}^N y_{ijt} \geq \sum_{k=1}^N y_{jkt} \quad j = 1, \dots, N; t = 1, \dots, T \quad (4.49)$$

As restrições (4.35), que são redundantes no modelo anterior, agora devem ser substituídas pelas restrições (4.50), que proíbem uma preparação para o produto para o qual a linha já está preparada no começo do período:

$$1 - z_{it} \geq \sum_{j=1}^N y_{jit} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.50)$$

As restrições (4.51) são necessárias para proibir uma nova preparação para o produto já configurado no começo do próximo período:

$$1 - z_{i,t+1} \geq \sum_{j=1}^N y_{ijt} \quad i = 1, \dots, N; t = 1, \dots, T-1 \quad (4.51)$$

Finalmente, as restrições (4.52) são necessárias para garantir que ocorra uma preparação depois do produto configurado no começo do período t . O caso raro de que não ocorra preparação em um determinado período é uma possibilidade alternativa que não é considerada na restrição (4.52).

$$z_{it} \leq \sum_{j=1}^N y_{ijt} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.52)$$

Reescrevendo as equações do modelo ATSP para a estratégia Sequências Dependentes, temos:

ATSP SEQÜÊNCIAS DEPENDENTES

$$\min \sum_{i=1}^N \sum_{t=1}^T h_{it} (I_{it}^+ + M I_{it}^-) + \sum c_{ot} O_t \quad (4.36)$$

sujeito a

$$I_{it}^+ - I_{it}^- = I_{i,t-1}^+ - I_{i,t-1}^- + q_{it} - d_{it} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.37)$$

$$\sum_{i=1}^N p_i q_{it} + \sum_{j=1}^N \sum_{li=1}^N st_{ji} y_{jit} \leq C_t + O_t \quad t = 1, \dots, T \quad (4.38)$$

$$y_{iit} = 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.39)$$

$$\sum_{i,j \in S_r} y_{ijt} \leq |S_r| - 1 \quad t = 1, \dots, T; S_r \subset PR, 2 \leq |S_r| \leq N - 2 \quad (4.40)$$

$$0 \leq O_t \leq u_t \quad t = 1, \dots, T \quad (4.41)$$

$$I_{it}^+, I_{it}^- \geq 0 \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.42)$$

$$y_{ijt} = 0 \text{ ou } 1 \quad i, j = 1, \dots, N; t = 1, \dots, T \quad (4.43)$$

$$q_{it} \geq 0 \text{ e inteiro } \quad \forall i, t \quad (4.44)$$

$$\sum_{i=1}^N z_{it} = 1 \quad t = 2, \dots, T \quad (4.45)$$

$$p_t q_{it} \leq (C_t + u_t) \left(z_{it} + \sum_{j=1}^N y_{jit} \right) \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.46)$$

$$q_{it} \geq lm_i \left(\sum_{j=1}^N y_{jit} - z_{it} \right) \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.47)$$

$$\sum_{i=1}^N y_{ijt} \leq \sum_{k=1}^N y_{jkt} + z_{j,t+1} \quad j = 1, \dots, N; t = 1, \dots, T-1 \quad (4.48)$$

$$z_{jt} + \sum_{i=1}^N y_{ijt} \geq \sum_{k=1}^N y_{jkt} \quad j = 1, \dots, N; t = 1, \dots, T \quad (4.49)$$

$$1 - z_{it} \geq \sum_{j=1}^N y_{jit} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.50)$$

$$1 - z_{i,t+1} \geq \sum_{j=1}^N y_{ijt} \quad i = 1, \dots, N; t = 1, \dots, T-1 \quad (4.51)$$

$$z_{it} \leq \sum_{j=1}^N y_{ijt} \quad i = 1, \dots, N; t = 1, \dots, T \quad (4.52)$$

4.3.3 Métodos de solução para os modelos ATSP

Para resolução destes modelos ATSP são utilizados dois métodos tradicionais para o problema do caixeiro viajante: eliminação de sub-rotas (Lawler *et al.*, 1985; Laporte, 1992; Pataki, 2003) e combinação de sub-rotas (*patching*) (Karp, 1979; Karp e Steele, 1985; Pekny e Miller, 1990; Carpaneto *et al.*, 1995; Frieze *et al.*, 1995; Glover *et al.*, 2001; Cirasella *et al.*, 2001; Zhang, 1993; Zhang, 1997).

Se o grupo de restrições que proíbe a formação de sub-rotas ((4.30) e (4.40)) for gerado para todas as possíveis sub-rotas S , temos a garantia de obtenção da solução ótima para o problema. Entretanto, dependendo do número de variáveis do problema, a complexidade computacional aumenta substancialmente, inviabilizando a obtenção da solução em tempo razoável. Conforme mencionado, a estratégia de solução deste modelo consiste basicamente no seguinte procedimento iterativo: ignora a proibição de sub-rotas; resolve o sub-modelo com o sequenciamento de lotes como um problema de designação; identifica as

sub-rotas encontradas nesta solução; e, resolve novamente o sub-modelo proibindo apenas as sub-rotas identificadas nas soluções anteriores. Esta estratégia de solução foi proposta em 1954 por Dantzig, Fulkerson e Johnson para resolver um problema com 49 cidades. Outros trabalhos que abordam esta estratégia podem ser encontrados em: Laporte e Nobert (1980); Lawler *et al.* (1985); Padberg e Rinaldi (1991); Applegate *et al.* (2003). A aposta desta estratégia é que em poucas iterações seja possível encontrar a solução ótima do problema. O procedimento de eliminar as restrições de sub-rotas nos modelos ATSP é mais bem explicado pelo algoritmo que se segue.

Eliminação de Sub-rotas:

```

Repetir {
  Resolve o modelo ATSP-Seq. Independentes ou ATSP-Seq. Dependentes
  proibindo somente aquelas sub-rotas encontradas até então (em
  qualquer período  $t$ ).
  # Comentário: Fornece um limite inferior para a solução ótima.
  Para  $t = 1, \dots, T$  faça {
    Identifica qualquer sub-rota no período e proíbe estas em
    todos os períodos a partir de então.
  }
  Resolve o modelo;
} Enquanto existir sub-rotas em qualquer período;
# Comentário: a solução é ótima agora.

```

Note que uma eventual solução factível sem sub-rotas não apresenta uma rota circular em cada período, mas uma única seqüência, começando com a família já preparada no começo do período e terminando com a última família preparada no período.

Um procedimento que pode acelerar a resolução do sequenciamento de lotes no modelo ATSP, proposto por Karp e Steele (1985), consiste em resolver o problema relaxado sem as restrições de proibição de sub-rotas, e então usar uma heurística de combinação (*patching*) para juntar as sub-rotas dentro de uma única seqüência. Na heurística *patching*, a cada iteração as duas maiores sub-rotas são identificadas e combinadas para construir uma nova rota da melhor forma possível, todas as possibilidades de junção entre elas são avaliadas (figura 4.9). Algumas aplicações e variações desta heurística podem ser encontradas nos

trabalhos de: Karp e Steele (1985); Frieze e Dyer (1990); Pekny e Miller (1990); Frieze et al. (1995); Carpaneto *et al.* (1995); Zhang (1993); Zhang (1997); Glover *et al.* (2000); Gutin e Zverovich (2000); Cirasella *et al.* (2001).




Figura 4.9 Ilustração da heurística de combinação de sub-rotas (*patching*).

Este método pode ser visto como uma extensão do método de eliminação de sub-rotas, onde em cada período as sub-rotas formadas são agrupadas para se obter uma única rota, geralmente gerando uma solução factível em relação às restrições de sub-rotas a cada iteração. No caso dos modelos ATSP apresentados, a melhor junção de sub-rotas é aquela que minimiza o aumento correspondente no tempo total de preparação. A solução obtida pode desobedecer às restrições de capacidade se a mesma for muito apertada e com pouca disponibilidade de hora extra.

Combinação e Eliminação de Sub-rotas (*Patching*):

```

Repetir {
  Resolve o modelo ATSP-carryover sem restrições de sub-rotas
  usando o menor limitante patching como solução inicial
  incumbente;
  # Comentário: fornece um limitante inferior para a solução ótima.
  Para  $t = 1, \dots, T$  faça {
    Identifica e proíbe quaisquer sub-rotas no período  $t$  em todos
    os períodos a partir de então;
  }
  Resolve o modelo;
  Para  $t = 1, \dots, T$  faça {

```

```
Junta (patch) as sub-rotas encontradas no período  $t$  em uma
única sequência;
}
Fixa as  $T$  seqüências (única rota) em  $t$  e resolve o modelo;
# Comentário: A solução factível resultante fornece um limite
superior para a solução ótima do modelo.
Desfaz a fixação das  $T$  seqüências;
}
Enquanto existir sub-rotas em qualquer período;
# Comentário: a solução é ótima agora.
```

5 EXPERIMENTOS COMPUTACIONAIS E ANÁLISE DE RESULTADOS

O objetivo neste capítulo é a avaliação de desempenho e validação das abordagens (modelos e métodos) propostas no capítulo 4. Para afirmar quais modelos são mais adequados para o problema integrado de dimensionamento e seqüenciamento de lotes na indústria de suplementos para nutrição animal, é necessário coletar dados reais, testar os modelos, analisando algumas conseqüências das suas aplicações, e comparar estes resultados com os resultados aplicados na prática da empresa estudada.

A execução dos experimentos computacionais foi realizada em três etapas com objetivos distintos. A primeira etapa consistiu na verificação dos modelos matemáticos e códigos computacionais, a partir de pequenos exemplos ilustrativos. Na segunda etapa foram realizados testes com dados reais, fornecidos pela empresa estudo de caso, onde as abordagens para solução do problema foram avaliadas. Nesta fase, o desempenho dos modelos e os planos de produção gerados puderam ser avaliados em relação à prática da empresa estudada. Finalmente, na terceira etapa foram realizados experimentos com dados aleatórios, com o objetivo de melhor analisar o desempenho das abordagens propostas em situações semelhantes e diferentes do estudo de caso. A execução destes experimentos teve dois princípios norteadores: a avaliação das características específicas do problema em questão, que o diferem dos problemas tratados na literatura; e, a avaliação das abordagens propostas diante da perturbação nos dados coletados no estudo de caso.

Todos os experimentos computacionais para as abordagens GLSP e ATSP foram realizados utilizando a linguagem de modelagem AMPL (Fourer *et al.*, 2003) com o *solver* CPLEX versão 9 (Ilog, 2004), em um processador Sun V208 Dual Opteron 252 com 1.5 GHz de RAM.

5.1 Experimentos com exemplos ilustrativos

Para avaliar a consistência dos modelos propostos (abordagens GLSP e ATSP), foram realizados alguns experimentos com exemplos simplificados, onde o número de períodos, subperíodos e produtos foi reduzido para simplificar a verificação dos códigos, o manuseio de dados, e a análise dos resultados obtidos em diferentes experimentos. A tabela 5.1 apresenta as diferenças de tamanho, o número de equações e variáveis de um problema típico no mundo real e o do exemplo simplificado, para os modelos GLSP, ATSP Seqüências

Dependentes e ATSP Sequências Independentes. Vale lembrar que os modelos GLSP Sequências Dependentes e GLSP Sequências Independentes possuem o mesmo número de variáveis e equações (conforme capítulo 4).

Tabela 5.1. Diferenças entre um problema real e o exemplo simplificado.

número de:		problema real	exemplo
dados	períodos (T)	4	2
	produtos (N)	26	3
GLSP	restrições	75929	201
	variáveis	75920	192
	variáveis discretas	5616	72
ATSP 'seq. dependentes'	restrições *	892	52
	variáveis	3094	39
	variáveis discretas	2886	27
ATSP 'seq. independentes'	restrições *	733	45
	variáveis	3016	36
	variáveis discretas	2808	24

* sem equações de sub-rotas

Considere um exemplo simplificado para o problema, onde, conforme antes, o índice i representa os produtos, isto é, $i = 1, 2, 3$. O horizonte de planejamento considerado é de apenas duas semanas, ou seja, o $t = 1, 2$. Para os modelos GLSP, cada período t é dividido em três subperíodos s , resultando em $S=NT=3 \times 2=6$. A seqüência de s não deve ser interrompida de um período t para outro, ou seja, $S_1 = \{1,2,3\}$ e $S_2 = \{4,5,6\}$. Esta consideração é importante principalmente para a modelagem do GSLP Sequências Dependentes, pois na mudança de um período para outro é sempre possível identificar $(s-1)$. Admite-se que não existem estoques iniciais ($I_{i0}=0$) e que no começo do horizonte de planejamento a linha de produção está limpa, ou seja, está preparada para qualquer produto ($x_{i0}=1$). Outros parâmetros necessários são: capacidade (C_t); disponibilidade de horas extras (u_t); custos de horas extras (co_t); tempos de produção (p_i); lote mínimo (lm_i); custos de estocagem (h_i); e, demanda (d_{it}).

A tabela 5.2 apresenta estes parâmetros para o exemplo simplificado (Exp.0), bem como algumas alterações nestes dados para realizar experimentos testando a consistência dos modelos. Desta forma, o experimento 1 consiste em uma redução na capacidade disponível em relação a Exp.0 (Exp.1, tabela 5.2). No experimento 2, a capacidade e a disponibilidade de horas extras são reduzidas (Exp.2, tabela 5.2). No experimento 3, além da

alteração na capacidade, é modificada a relação entre os custos de estocagem e horas extras (Exp.3, tabela 5.2). Já no experimento 4, os tempos de preparação são aumentados e a demanda é ajustada para gerar um exemplo factível em relação à capacidade produtiva (Exp 4, tabela 5.2).

Parâmetros	Exp.0	Exp.1	Exp.2	Exp.3	Exp.4
C_1	64	58	58	58	64
C_2	64	60	58	60	64
u_1	6	6	6	10	6
u_2	8	8	4	10	8
co_1	5	5	5	5	5
co_2	5	5	5	12	5
p_1	2,5	2,5	2,5	2,5	2,5
p_2	3	3	3	3	3
p_3	1,5	1,5	1,5	1,5	1,5
h_1	20	20	20	20	20
h_2	30	30	30	30	30
h_3	10	10	10	10	10
d_{11}	13	13	13	13	15
d_{12}	11	11	11	11	5
d_{21}	7	7	7	7	2
d_{22}	9	9	9	9	9
d_{31}	5	5	5	5	2
d_{32}	6	6	6	6	23
st_{11}	0	0	0	0	0
st_{12}	0,16	0,16	0,16	0,16	5
st_{13}	0,16	0,16	0,16	0,16	5
st_{21}	1	1	1	1	8
st_{22}	0	0	0	0	0
st_{23}	0,16	0,16	0,16	0,16	5
st_{31}	0,16	0,16	0,16	0,16	5
st_{32}	1	1	1	1	8
st_{33}	0	0	0	0	0

Note na tabela 5.2 que a desigualdade triangular (4.6) não se aplica. Por exemplo, para produzir o produto 2 depois de 3, é necessário um tempo de preparação (st_{32}) de 1 hora. Entretanto, se depois do produto 3 ocorrer a produção do produto 1, é necessário um tempo de preparação (st_{31}) de apenas 0,16 horas, pois neste exemplo o produto 1 não é contaminado pelos resíduos do 3. Produzindo-se o produto 2 na seqüência temos um tempo de preparação (st_{12}) de 0,16 horas. Portanto $st_{31}+st_{12}= 0,32$ é menor do que $st_{32}=1$, o que viola a desigualdade triangular (4.6). Neste caso, o produto 1 funciona como um ‘produto limpante’.

A tabela 5.3 apresenta o programa de produção gerado pelo modelo GLSP Sequências Dependentes (4.1)-(4.10), sem incluir o termo de penalização para preparação (4.1a). Para o modelo ATSP Sequências Dependentes (4.36)-(4.52) os resultados são os mesmos. Para cada experimento são dispostas na tabela 5.3 duas colunas, uma indica o produto (i) e a outra sua respectiva quantidade (q_{is}) a ser produzida no período (indicado na primeira coluna). A ordem em que os produtos (i) são colocados nas linhas indica a seqüência gerada, por exemplo, para o experimento 3, a seqüência do primeiro período é 2-3-1.

t	Exp.0		Exp.1		Exp.2		Exp.3		Exp.4	
	i	q_{is}	i	q_{is}	i	q_{is}	i	q_{is}	i	q_{is}
1	2	7	1	13	1	14	2	7	3	2
	1	13	2	7	2	7	3	7	1	20
	3	5	3	5	3	5	1	13	2	2
2	1	11	3	6	3	6	1	11	2	9
	2	9	1	11	1	10	2	9	3	23
	3	6	2	9	2	9	3	4		

O tempo computacional para gerar estes resultados é menor que um segundo, tanto para o modelo GLSP Sequências Dependentes quanto para o ATSP Sequências Dependentes.

A figura 5.1 representa o balanceamento de estoques em cada período $t = 1, 2$ para o experimento inicial, obtido por meio da resolução do modelo GLSP. Nesta figura podemos observar que a demanda em cada período é totalmente atendida, sem utilizar estoques intermediários.




Figura 5.1 – Resultados do exemplo simplificado (Exp. 0).

A seqüência dos produtos pode ser definida pelos subperíodos s no modelo GLSP Seqüências Dependentes, e pelas variáveis y_{jit} no modelo ATSP Seqüências Dependentes. A partir das seqüências apresentadas na tabela 5.3 e dos parâmetros da tabela 5.2, apresentamos o seqüenciamento de lotes detalhado na figura 5.2.




Figura 5.2 – Seqüenciamento para o exemplo simplificado (Exp.0).

Na figura 5.2, os números dentro dos retângulos correspondem ao produto que está sendo produzido, e seus tamanhos estão relacionados à quantidade de tempo necessária para a produção ($p_i q_{is}$ no modelo GLSP Seqüências Dependentes e $p_i q_{it}$ no modelo ATSP Seqüências Dependentes). Por exemplo, o primeiro produto da seqüência em $t = 1$ é o produto 2, e o tempo utilizado para sua produção é 21 horas. As áreas hachuradas correspondem aos tempos de preparação, e não estão em escala na figura. Note que, neste exemplo, existem dois tamanhos distintos para os tempos de preparação: um corresponde à preparação quando ocorre mudança de uma família para outra sem que exista, entre elas, problemas de contaminação ($st_{ji}=0,16$ horas); outro quando uma família possui ingredientes em sua formulação que são contaminantes para a próxima ($st_{ji}=1$ hora). Quando não existe mudança de um produto para outro ($j=i$), não temos preparação ($st_{ji}=0$), mas esta situação não ocorre neste exemplo.

Para o modelo GLSP, os tamanhos dos subperíodos s correspondem ao tempo de preparação necessário para que ocorra produção no período, mais o tempo utilizado para a produção. Por exemplo, na figura 5.2, podemos notar que o tamanho do subperíodo $s3$ em $t = 1$ é 7,66 horas [$st_{13}+(p_3q_{33})$].

Observe que a demanda é atendida com a capacidade normal do sistema produtivo em cada período (figura 5.2), sem a necessidade de incorrer em horas extras ou estocagem de um período para outro. Portanto, como esperado, o valor da função objetivo

(custo de estocagem e hora extra) é zero. Uma solução ótima alternativa seria produzir as mesmas quantidades, mas na seqüência 1-2-3-3-1-2.

Como no começo do horizonte de planejamento considera-se que a linha está limpa ($x_{i0} = 1$), ou seja, preparada para qualquer produto, não ocorre uma preparação inicial. Pela figura 5.2 podemos visualizar que no primeiro período ($t = 1$) o tempo total de preparação ($st_{21} + st_{13}$) é de 1,16 horas. Os modelos não otimizam a seqüência de forma a minimizar o tempo total consumido na preparação, pois existe capacidade ociosa para atender a demanda e, para estes experimentos, o termo de penalização (4.1a) não está incluído na função objetivo. No segundo período ($t = 2$) o tempo total de preparação é de 0,48 horas, pois o modelo procura otimizar a seqüência de maneira que o tempo total de produção mais o tempo total de preparação não ultrapassem o limite de capacidade (C_t), pois a utilização de horas extras implicaria em uma penalização nos custos.

Notamos que, para este exemplo simplificado, o modelo não gerou apenas resultados binários para a variável y_{jis} ($y_{323} = 1,84$ e $y_{326} = 0,02$). Isto é explicado pelo fato de existir capacidade ociosa no período $t = 1$ e no período $t = 2$, e a função objetivo não incluir custos de preparação (como no modelo de Meyr (2000)) ou mesmo o termo de penalização (4.1a) proposto no capítulo 4. Note, entretanto, que isto não compromete as decisões ótimas do modelo.

A seguir são apresentados os resultados com os experimentos 1, 2, 3 e 4 (Exp.1, Exp.2, Exp.3 e Exp.4).

Experimento 1 – A disponibilidade de capacidade é alterada (conforme tabela 5.2), forçando a utilização de horas extras. Os resultados (tabela 5.2) mostram que novamente a demanda é atendida sem a necessidade de estocagem de um período para outro, desta forma, o balanceamento de estoques para este plano de produção é idêntico ao apresentado na figura 5.1.. O seqüenciamento de lotes detalhado para este experimento está ilustrado na figura 5.3.




Figura 5.3 – Seqüenciamento para o experimento 1.

Comparando as figuras 5.2 e 5.3, podemos observar que a seqüência do experimento inicial, com 5 preparações e tempo total de preparação ($st_{21} + st_{13} + st_{31} + st_{12} + st_{23}$) de 1,64 horas, foi alterada, resultando em apenas 4 preparações, com um tempo total de preparação ($st_{12} + st_{23} + st_{33} + st_{31} + st_{12}$) de apenas 0,64 horas. Pela figura 5.3 podemos observar que, no período $t=1$ são utilizadas 61,32 horas ($32,5+0,16+21+0,16+7,5$), das quais 3,32 são horas extras (O_1), e no período $t=2$ são necessárias 63,82 horas ($9+0,16+27,5+0,16+27$), das quais 3,82 são horas extras (O_2). Isto resulta em um custo total de horas extras de 35,7. No exemplo Exp.0 são necessárias 62,16 horas para cumprir o plano de produção no período $t = 1$, e 63,98 em $t = 2$. Se este plano de produção fosse utilizado nas novas condições de capacidade consideradas no experimento 1, resultaria em um custo total de 40,7, que é 14% maior que o custo resultante do plano de produção gerado pelo experimento 1.

Conforme previsto, quando não existe capacidade ociosa, o modelo otimiza a seqüência para que os tempos de preparação tenham um menor impacto na capacidade produtiva, minimizando a utilização e, conseqüentemente, os custos de horas extras.

Quanto à variável y_{jis} , para este exemplo, notamos que ela assume apenas valores binários. Outros experimentos computacionais foram realizados (a partir do Exp.0 e do Exp.1) declarando a variável y_{jis} como binária, para analisar eventuais mudanças nos resultados. Constatamos que não ocorrem alterações nos planos de produção ou na seqüência, o que era esperado da discussão do capítulo 4.

Experimento 2: Os dados do exemplo inicial Exp.0 foram alterados de forma a forçar a estocagem do primeiro para o segundo período, conforme tabela 5.2. Os resultados apresentados na tabela 5.3 mostram que a quantidade produzida foi alterada em relação aos resultados do experimento inicial, conforme pode ser visto na figura 5.4.

Como esperado, como o período $t=2$ não tem capacidade suficiente para atender a demanda, no período $t=1$ são produzidas 14 bateladas do produto 1 ($q_{11}=14$), das quais apenas 13 bateladas são demandadas neste período ($d_{11}=13$) e 1 batelada é estocada para ser utilizada em $t=2$ ($I_{11}=1$). Como a quantidade produzida é uma variável discreta (em número de bateladas), somente é possível adiantar uma batelada inteira.




Figura 5.4 – Resultados do experimento 2.

Como os limites de capacidade continuam restritivos, a seqüência produtiva não é alterada em relação ao experimento 1. A diferença é que o tempo necessário para produção no período $t = 1$ aumentou de 61,32 para 63,82, pois são necessárias mais 2,5 horas para adiantar a produção de uma batelada do produto 1.

Note que, apesar do custo de estocagem do produto 1 ($h_1=20$) ser maior que do produto 3 ($h_3=10$), ele foi escolhido para ter sua produção adiantada. Para verificar porque esta é a melhor solução, vamos analisar a alternativa de estocar uma batelada do produto 3, ao invés do produto 1. As capacidades necessárias para produzir as demandas sem estocar são 61,32 e 63,82 nos períodos $t = 1$ e $t = 2$, respectivamente. Adiantando a produção de uma batelada do produto 3 para o período $t = 1$, seriam necessárias 62,82 horas de produção em $t = 1$ e 62,32 em $t = 2$. Como a capacidade total disponível em $t=2$ ($C_2 + u_2$) é de 62 horas, ainda não seria possível atender a demanda. Outra possibilidade seria produzir 2 bateladas do produto 3 no período $t = 1$, o que igualaria os custos de estocagem. Para isto, seriam necessárias 64,32 horas de produção, o que violaria a restrição de capacidade do primeiro período.

Foram utilizadas 5,82 horas extras no período $t = 1$ e 3,32 horas extras no período $t = 2$, resultando em um custo de horas extras de 45,7. O custo de estocagem corresponde a estocagem do produto 1 de $t = 1$ para $t = 2$. Desta forma, o valor da função objetivo (custo total) é de 65,7.

Experimento 3: Conforme apresentado no experimento 2, uma das alternativas do modelo para ajustar a capacidade produtiva é produzir antecipadamente em um período e estocar esta quantidade para utilização no outro período. No experimento 1 esta alternativa não é utilizada, pois os custos de estocagem são grandes quando comparados aos de hora extra, e no experimento 2, somente é utilizada devido à restrição de capacidade que foi imposta. Desta

forma, neste experimento a disponibilidade de horas extras e os seus custos em relação aos custos de estocagem são aumentados (tabela 5.2).

Os resultados obtidos estão na tabela 5.3. Note que as quantidades produzidas em cada período mudaram em relação ao experimento 1. São estocadas 2 bateladas do produto 3 ($I_{31}=2$) do período $t = 1$ para $t = 2$, o que é melhor visualizado na figura 5.5.




Figura 5.5 – Resultados do experimento 3.

Como pode ser visto na figura 5.6, a seqüência produtiva, embora diferente da apresentada na figura 5.3, é equivalente. Isto é, possui o mesmo número de preparações e tempo total de produção. No período $t = 1$ são utilizadas 64,32 horas, das quais 6,32 são horas extras, e no período $t = 2$ são utilizadas 60,82 horas, das quais 0,82 são horas extras, resultando em um custo total de: $6,32 * 5 + 0,82 * 12 + 2 * 10 = 61,44$.




Figura 5.6 – Seqüenciamento para o experimento 3.

Se ao invés de estocar, o plano de produção gerado optasse pela utilização apenas de horas extras (como no experimento 1), o custo total seria de: $5 * 3,32 + 12 * 3,82 = 62,44$. Ou seja, aumentando os custos de horas extras do período $t=2$, notamos que compensa utilizar a estratégia de estocar no período $t=1$, onde os custos de horas extras são menores.

Experimento 4: Neste experimento os tempos de preparação são aumentados (tabela 5.2), para verificar se os modelos agrupam os lotes de produção. Com os resultados obtidos (tabela 5.3), temos o balanceamento de estoques apresentado na figura 5.7.

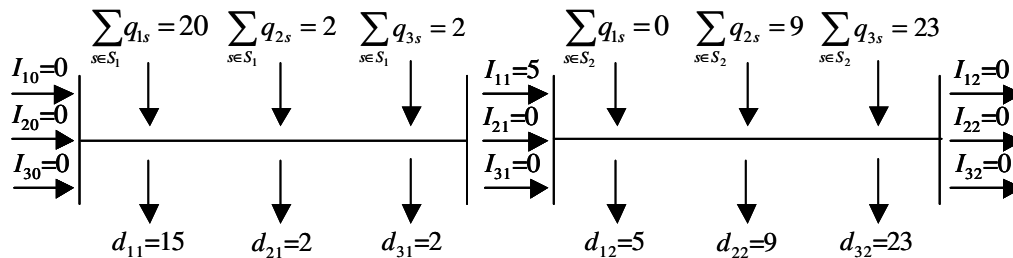


Figura 5.7 – Resultados do experimento 4.

Note que no primeiro período são atendidas as demandas de núcleo dos períodos $t=1$ e $t=2$, agregando em um único lote, o que reduz o número e o tempo de preparações (figura 5.8). Entre os períodos não há mudança de produto, portanto, não há preparação. Note que ocorre mudança de produto somente três vezes, isto é, y_{312} , y_{123} , $y_{235} = 1$ no caso do modelo GLSP, e y_{311} , y_{121} , $y_{232} = 1$, no caso do modelo ATSP.




Figura 5.8 – Seqüenciamento para o experimento 4.

Conforme esperado, quando aumentamos o tempo de preparação, aumentamos seu impacto no consumo de capacidade, o que força o modelo a agregar as quantidades a serem produzidas em lotes maiores, reduzindo o número e tempo total das preparações.

Estes resultados mostram que os modelos (4.1)-(4.10) e (4.36)-(4.52), bem como suas implementações computacionais, se comportam conforme esperado e parecem representar bem o presente problema, resultando em soluções consistentes à medida que os parâmetros do modelo são alterados.

Os mesmos experimentos foram realizados para os modelos da abordagem

Seqüências Independentes. A diferença significativa nos resultados é a realização de mais preparações, ou seja, as preparações dentro de cada período, mais a limpeza completa na linha de produção ao final de cada período. Produzir o mesmo produto no final do período 1 e no início do período 2 deixa de ser uma estratégia interessante para redução do tempo total de preparações.

Nos resultados das abordagens de solução ATSP é interessante ressaltar algumas particularidades. Os experimentos realizados com o modelo ATSP Seqüências Independentes (4.21)-(4.36) usando a abordagem de solução de proibição de sub-rotas encontra a solução ótima em duas iterações. Na primeira, o modelo é resolvido relaxando-se a proibição de sub-rota. O procedimento de verificação de ocorrência de sub-rotas é realizado encontrando apenas uma sub-rota. Na segunda iteração, a sub-rota encontrada é proibida pela restrição (4.30), e o modelo encontra a solução ótima. No caso do modelo ATSP Seqüências Dependentes, a solução ótima é encontrada em uma única iteração.

5.2 Experimentos com Dados Reais

A seguir são apresentados e analisados os principais resultados obtidos na execução dos experimentos computacionais com os dados reais fornecidos pela empresa. Estes experimentos foram realizados usando todos os parâmetros ‘*default*’ do pacote AMPL/CPLEX versão 9.0. De acordo com Atamtürk e Savelsberg (2005), os parâmetros que controlam o algoritmo *branch-and-cut* são ajustados de forma genérica. Dependendo da estrutura particular de alguns problemas, pode ser interessante um ajuste fino destes parâmetros. Foram realizados alguns estudos dos impactos da alteração dos parâmetros CPLEX para o modelo ‘GLSP Seqüências Dependentes’, entretanto os resultados não apresentaram melhoras significativas em termos de qualidade de solução e tempos computacionais. Os resultados destes experimentos encontram-se no anexo B.

Todos os experimentos foram limitados em uma hora (3600 segundos) de processamento computacional, desta forma, algumas soluções encontradas, principalmente para os modelos GLSP, correspondem a soluções heurísticas MIP truncado (Pochet e Wolsey, 2006). Uma forma de mensurar a qualidade destas soluções heurísticas é através do *gap* de otimalidade ou *gap* de dualidade, que é calculado da seguinte forma:

$$Gap\ Dualidade = \frac{MelhorLS - MelhorLI}{MelhorLS} \times 100 [\%],$$

onde *MelhorLI* é o melhor limitante inferior e *MelhorLS* é o melhor limitante superior

(solução incumbente) (Pochet e Wolsey, 2006).

5.2.1 Caracterização dos dados coletados

Os parâmetros de entrada para os modelos correspondem a dados reais coletados na empresa estudada em períodos distintos. Cada horizonte de planejamento corresponde a quatro semanas de produção ($t = 1, 2, 3, 4$). Os dois primeiros meses (mesA e mesB) são os mesmos utilizados em Toso e Morabito (2005), e os demais meses (mes1, mes2, ..., mes7) referem-se a dados coletados mais recentemente. Estes dados correspondem: a previsões de demanda de cerca de 200 produtos que foram agrupados em 26 famílias; a capacidade produtiva disponível em cada período; o limite de tempo disponível para horas extras que geralmente corresponde a cerca de 25% da capacidade; os tempos de preparação dependentes da seqüência que podem ser 0 ou 1,67 horas; os tempos de processamento por produto; as estimativas de custos de horas extras e estocagem; e os lotes mínimos para cada produto. Sem perda de generalidade, os estoques iniciais foram descontados da demanda, fixando-se valores nulos para todos os produtos. Vale ressaltar que, por motivos de confidencialidade e para proteger os interesses da empresa, os dados fornecidos pela empresa foram distorcidos, mantendo-se apenas sua proporcionalidade. Uma tabela completa com todos estes dados encontra-se no anexo A.

A tabela 5.4 mostra uma caracterização resumida destes dados. A segunda coluna mostra o número de famílias de produtos com demanda positiva em cada conjunto de dados. As próximas quatro colunas apresentam a distribuição destas famílias por grau de contaminação. Por exemplo, no mesA, das 18 famílias demandadas, 4 famílias tem grau de contaminação 1, 9 famílias tem grau de contaminação 2, e assim sucessivamente. O grau de contaminação de cada família indica o quanto ela é crítica para contaminação. Este grau de contaminação foi obtido a partir da matriz de tempos de preparação, calculando-se um tempo médio de preparação necessário depois de cada produto, mais o tempo médio de preparação para cada produto $\left(\sum_{j=1}^N st_{ji} + \sum_{i=1}^N st_{ji} \right) \div 2N$. Com os resultados, foram estabelecidas as seguintes faixas que correspondem ao grau de contaminação:

- Até 20 minutos --- grau 1 (menos crítico para contaminação);
- Entre 20 e 28 minutos --- grau 2;

- Entre 28 e 35 minutos --- grau 3;
- Acima de 35 minutos --- grau 4 (mais crítico para contaminação).

Dados	Nº famílias	Distribuição/ Grau de Contaminação				Capacidade Necessária (%)				
		1	2	3	4	t=1	t=2	t=3	t=4	média
mês A	18	4	9	3	2	90	88	96	117	97,75
mês B	15	2	7	2	1	97	104	126	91	104,5
mês 1	20	5	11	3	1	87	85	103	116	97,75
mês 2	21	4	10	5	2	78	102	91	129	100
mês 3	18	5	10	2	1	93	92	108	94	96,75
mês 4	19	5	10	2	1	73	76	88	104	85,25
mês 5	22	5	9	5	2	81	96	104	135	104
mês 6	18	5	10	2	1	87	92	95	134	102
mês 7	20	5	11	2	2	84	105	94	132	103,75

Conforme discutido no capítulo 4 e tabela 5.1, a aplicação dos modelos GLSP seqüências dependentes ((4.1)-(4.10)) e GLSP seqüências independentes ((4.11)-(4.20)) na unidade produtora de suplementos, considerando a programação da produção de 26 famílias ($N=26$) durante um horizonte de planejamento de 4 semanas ($T=4$), resulta em um problema com 75928 restrições e 75920 variáveis. Para o modelo ATSP seqüências independentes, a programação resulta em 733 restrições e 3016 variáveis inteiras ou binárias, na primeira iteração do método, isto é, sem restrições de eliminação de sub-rotas. No caso do modelo ATSP seqüências dependentes, ela resulta em 892 restrições e 3094 variáveis inteiras ou binárias.

Nos estudos computacionais com experimentos reais, o termo de penalização dos tempos de preparação (4.1a) foi incluído na função objetivo em todos os modelos.

5.2.2 Estudos computacionais para a estratégia Seqüências Independentes

O modelo GLSP Seqüências Independentes (4.11)-(4.20) foi resolvido pelo método exato *branch-and-cut* do pacote AMPL/CPLEX. Já o modelo ATSP Seqüências Independentes ((4.21)-(4.35)) foi resolvido pela combinação *do branch-and-cut* com o procedimento de eliminação de sub-rotas apresentado no capítulo 4. Os resultados destes experimentos, obtidos no limite de tempo de uma hora, encontram-se na tabela 5.5. A

primeira coluna corresponde à identificação das instâncias testadas, seguido dos valores para o modelo GLSP (função objetivo; tempo computacional, em segundos, em que a solução foi obtida; *gap* de otimalidade) e dos valores para o modelo ATSP (função objetivo; tempo computacional, em segundos, em que a solução foi obtida; número de iterações; número de sub-rotas encontradas; *gap* de otimalidade). Os melhores resultados da função objetivo e tempo computacional estão destacados (em negrito) na tabela.

Cabe ressaltar que, na tabela 5.5, os tempos computacionais para o modelo GLSP seqüências independentes correspondem ao valor em que a solução foi obtida, dentro do tempo limite de uma hora, enquanto que os tempos computacionais do modelo ATSP seqüências independentes, correspondem ao tempo de resolução até a otimalidade.

	GLSP			ATSP				
	f.o.	tempo	<i>gap</i> (%)	f.o.	tempo	iterações	sub-rotas	<i>gap</i> (%)
mesA	3028	2860 / 3600	3,28	3028	336	60	240	0
mesB	15425	779 / 3600	0,18	15425	9	28	86	0
mes1	4029	706 / 3600	1,08	4023	3542	118	587	0
mes2	7655	2531 / 3600	4,69	7655	2011	194	916	0
mes3	3207	968 / 3600	0,99	3207	460	160	686	0
mes4	3378	234 / 3600	5,31	3378	104	97	419	0
mes5	13056	28 / 3600	0	13056	43	113	486	0
mes6	9611	790 / 3600	0,23	9611	399	14	76	0
mes7	9088	2579 / 3600	6,09	9076	3600	4	20	0,22
média	7609	1275 / 3600	2,43	7607	1167	88	391	0

Observe nos resultados para o modelo GLSP seqüências independentes, que uma garantia de otimalidade é obtida somente para o mes5, e em apenas 28 segundos. Embora este modelo não forneça uma solução com garantia de otimalidade para os outros meses, as soluções obtidas são bem próximas do valor do limitante inferior (o *gap* de otimalidade em média é 2,43%). Na maior parte dos experimentos realizados, uma primeira solução é rapidamente encontrada e seu valor não apresenta melhoras significativas ao longo do tempo limite de uma hora. O tempo médio em que as soluções foram encontradas é 1275 segundos. Os gráficos na figura 5.9 ilustram o desempenho computacional para os experimentos mesB, mes2, mes3 e mes7 do modelo GLSP.

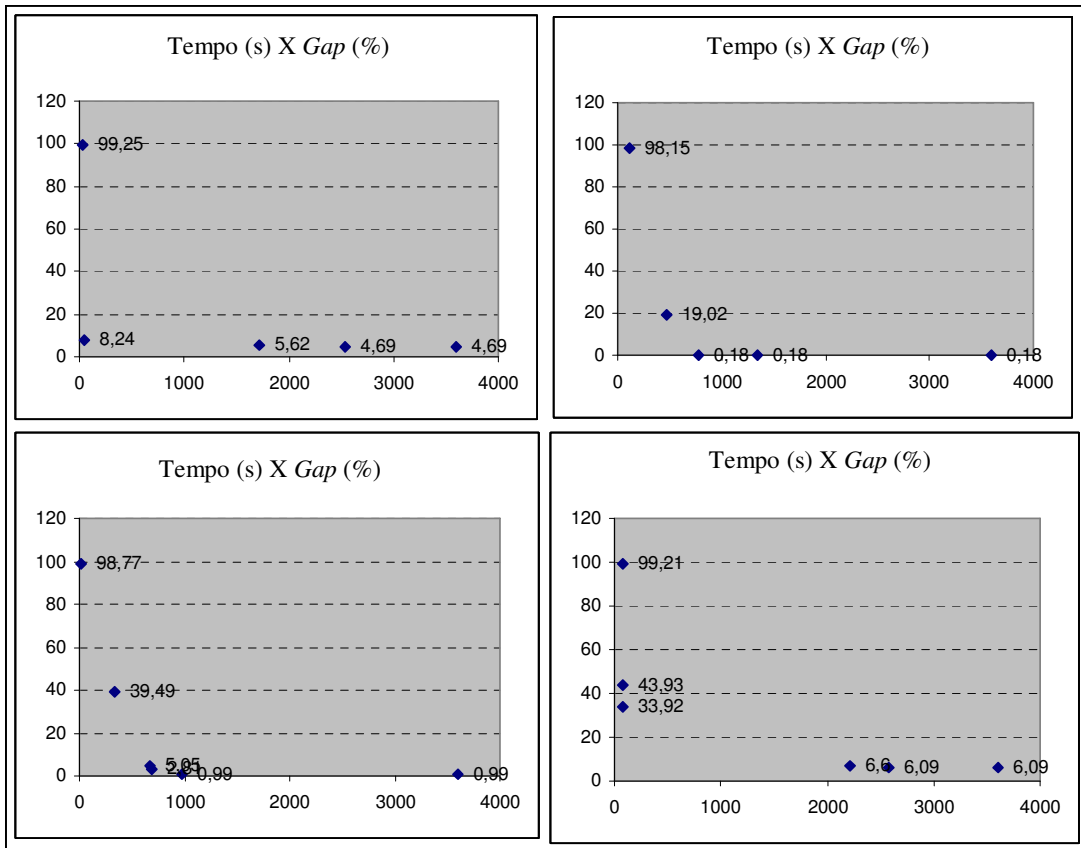


Figura 5.9 – Gráficos ilustrando o desempenho computacional de alguns experimentos com modelo GLSP Seqüências Independentes.

Quanto aos resultados do modelo ATSP, note na tabela 5.5 que, exceto para o mes7, os experimentos realizados encontraram uma solução com garantia de otimalidade em menos de uma hora de processamento computacional. Além dos valores da função objetivo e tempo total de processamento (em segundos), a tabela 5.5 apresenta o número de iterações para resolução de cada experimento e o número de sub-rotas encontradas e proibidas pelo método. Observe que, em geral, quanto maior o número de iterações, maior o número de sub-rotas encontradas. Em relação aos tempos computacionais, existe muita variação, com o menor tempo para o experimento mesB, e maior para o experimento mes7, onde o resultado encontrado não é provado ser ótimo, apresentando um *gap* de otimalidade de apenas 0,22%.

Note na tabela 5.5 que, exceto pelas instâncias mes1 e mes7, em todos os experimentos realizados, o valor da função objetivo é o mesmo para os modelos GLSP seqüências independentes e ATSP seqüências independentes, entretanto, o tempo computacional varia bastante. A abordagem ATSP foi melhor ou igual a abordagem GLSP em todos os exemplos em termos de qualidade da solução, mas foi pior em termos de tempo

computacional nos exemplares mes1, mes5 e mes7 (quando ambos ATSP e GLSP geram a mesma solução). Em seis dos nove experimentos realizados, a estratégia ATSP teve melhor desempenho computacional (destacados na tabela). Em média o ATSP é cerca de 17% mais rápido que o GLSP. Em apenas dois experimentos o GLSP foi melhor (mes1 e mes5), e para o exemplar mes7, embora o GLSP tenha sido mais rápido, o valor da sua função objetivo é pior. Uma diferença importante entre estas abordagens é que, dada a limitação do tempo de 3600 segundos, a abordagem ATSP sempre converge para a solução ótima dentro deste limite (exceto para o mes7, em que este limite foi atingido), enquanto que as soluções GLSP, mesmo depois de uma hora de execução, não têm garantia de otimalidade.

Nos programas de produção gerados pela abordagem com seqüenciamento independente entre os períodos, toda a demanda é atendida dentro do horizonte de planejamento, não ocorrem atrasos ou faltas. A tabela 5.6 apresenta um resumo do melhor programa de produção resultante. Para todos os conjuntos de dados são apresentados: a capacidade utilizada em cada período (em porcentagem); as horas extras necessárias em cada período e o número de preparações ou limpezas necessárias para evitar a contaminação cruzada dentro do período.

Dados	Capacidade utilizada				Horas Extras				Preparações
	$t=1$	$t=2$	$t=3$	$t=4$	$t=1$	$t=2$	$t=3$	$t=4$	
mesA	90.8	100	100	100	0	0	0	0	0
mesB	100	102.2	125	90.9	0	1.4	16	0	0
mes1	91	100	100	100.2	0	0	0	0.1	1 em $t=3$
mes2	100	100	100	102.9	0	0	0	1.5	1 em $t=1$
mes3	93.5	99.8	100	94,3	0	0	0	0	0
mes4	73.1	75.6	91.5	99.8	0	0	0	0	0
mes5	100	100	100	115.8	0	0	0	8.2	0
mes6	99.8	100	100	107.9	0	0	0	4.1	0
mes7	99.7	100	100	119	0	0	0	8	1 em $t=1$

Note na tabela 5.6 que somente nos experimentos mes1, mes2 e mes7 são necessárias as preparações. Isto ocorre porque, como consequência do seqüenciamento independente, os produtos mais contaminantes são alocados ao final de cada período, não considerando que deve existir uma preparação para iniciar a produção no próximo período.

Desta forma, é importante a pressuposição de que é necessário fazer uma limpeza ao final de cada período.

Observe nas tabelas 5.5 e 5.6 que ambas as abordagens antecipam a produção, evitando sempre que possível a utilização de horas extras. Entretanto, conforme discutido adiante, a estratégia adotada pela empresa é acompanhar a demanda, recorrendo quando necessário às horas extras. Como esta abordagem pressupõe a realização de uma limpeza ao final de cada período, são necessárias pelo menos 2,6% da capacidade produtiva para esta tarefa. No entanto, não existe capacidade disponível em todos os períodos (tabela 5.6). Desta forma, para estes conjuntos de dados analisados, esta estratégia implica necessariamente em um custo extra.

5.2.3 Estudos computacionais para a estratégia Seqüências Dependentes

Devido à maior complexidade deste problema, os estudos computacionais foram mais abrangentes, testando-se vários métodos de solução para cada modelo. As instâncias com o modelo GLSP seqüências dependentes foram resolvidas pelos seguintes métodos: *branch-and-cut*; *relax-and-fix* variáveis; *relax-and-fix* períodos (conforme apresentado no capítulo 4) todos usando o pacote (AMPL/CPLEX). As instâncias com o modelo ATSP seqüências dependentes foram resolvidas pelos métodos: *branch-and-cut* com eliminação de sub-rotas; e, *branch-and-cut* com eliminação e combinação de sub-rotas (*patching*). Desta forma, esta seção é subdividida em: abordagens GLSP; abordagens ATSP; e comparação destas abordagens para a estratégia Seqüências Dependentes.

5.2.3.1 Abordagens GLSP

Os resultados dos experimentos com o modelo GLSP Seqüências Dependentes (4.1)-(4.10), incluindo o termo de penalização de tempos de preparação (4.1a) na função objetivo, são apresentados na tabela 5.7. Como na tabela 5.5, a primeira coluna corresponde à identificação das instâncias, seguida dos valores para o método *branch-and-cut*, *relax-and-fix* variáveis e *relax-and-fix* períodos. Para cada método os resultados apresentados são: função objetivo, tempo computacional (em segundos) em que esta solução foi obtida (no tempo limite de uma hora) e *gap* de otimalidade, exceto para o método *relax-and-fix* períodos onde não foi possível obter o *gap* de otimalidade. No caso do *gap* de otimalidade para o método

relax-and-fix períodos, o resultado apresentado consiste no valor obtido para a primeira etapa do procedimento, onde as variáveis de dimensionamento de lotes estão relaxadas. Os melhores resultados da função objetivo e tempo computacional estão destacados (em negrito) na tabela 5.7.

	<i>branch-and-cut</i>			<i>relax-and-fix</i> variáveis			<i>relax-and-fix</i> períodos	
	f.o.	tempo	gap (%)	f.o.	tempo	gap (%)*	f.o.	tempo
mesA	3519	360	16,58	3453	273	13,9	3445	415
mesB	16616	157	7,32	16616	132	7,29	16616	511
mes1	4312	339	7,58	4312	132	6,69	4312	115
mes2	8176	438	10,76	8176	258	10,5	8176	65
mes3	4328	1049	10,85	4328	240	7,69	4589	1243
mes4	3378	2854	5,47	3378	183	0,1	3378	2150
mes5	13510	775	3,36	13510	117	3,12	13510	341
mes6	10019	345	4,3	10019	128	4,23	10019	227
mes7	11597	2998	15,87	10726	484	13,03	10851	1506
média	8384	1035	9,12	8280	216	7,39	8322	730

* Valor do *gap* de otimalidade da primeira etapa do método.

Vale lembrar que as soluções encontradas não têm garantia de otimalidade. O valor médio do *gap* de otimalidade para os experimentos com o método *branch-and-cut* é de 9,12%, enquanto do método *relax-and-fix* variáveis é menor, 7,39%. O tempo médio em que as melhores soluções são encontradas é 1035 segundos para os experimentos com o método *branch-and-cut*, de 216 segundos para o método *relax-and-fix* variáveis, e de 730 segundos para o *relax-and-fix* períodos. Ainda em relação ao tempo, é necessário enfatizar que o desempenho computacional segue o mesmo padrão dos experimentos para a abordagem GLSP seqüências independentes, isto é, embora os experimentos tenham sido executados até o limite de tempo, as soluções apresentadas na tabela 5.7 foram encontradas bem antes.

Conforme esperado, os resultados da função objetivo da estratégia Sequências Dependentes, que correspondem aos custos totais de estocagem, falta e horas extras, são maiores que os resultados da estratégia Sequências Independentes. Vale lembrar que estes valores não são diretamente comparáveis, pois a estratégia Sequências Independentes já considera uma limpeza ao final de cada período, diminuindo os custos de eventuais horas extras.

Os *gaps* de otimalidade e os tempos computacionais destes experimentos,

principalmente para o caso da estratégia Sequências Dependentes, são pouco viáveis para aplicações práticas onde é necessário o desenvolvimento de uma ferramenta computacional mais eficiente que possibilite, por exemplo, estudos de geração e análise de cenários.

Alguns experimentos iniciais com o método ‘*Relax-and-Fix Variáveis*’ mostraram que resolver o primeiro passo da heurística, que consiste na resolução do modelo (4.1)-(4.10) com a condição de integralidade de q_{is} relaxada, ainda requer muito esforço computacional, enquanto que o segundo passo é resolvido em poucos segundos. Desta forma, o tempo limite de 1 hora foi determinado para a resolução do primeiro passo.

Os valores da função objetivo para o método *relax-and-fix* variáveis corresponde ao valor da solução da heurística (primeiro e segundo passos). Comparando com os valores da função objetivo obtidos nos experimentos do método *branch-and-cut* (tabela 5.7), verifica-se que o método *relax-and-fix* variáveis consegue resultados melhores em dois experimentos (mesA e mes7). Uma comparação entre os tempos computacionais mostra que o método *relax-and-fix* variáveis encontra os mesmos valores de função objetivo com menos tempo de processamento computacional, entretanto, embora esta abordagem encontre limitantes superiores para o problema mais rapidamente, não consegue provar a otimalidade desta solução em 1 hora de processamento. No segundo passo, uma vez que os valores das variáveis de seqüenciamento estão fixados, a solução ótima é encontrada em poucos segundos.

Foram realizados experimentos iniciais com o método *relax-and-fix* períodos de $t = 1, \dots, T$ (*forward*) e de $t = T, \dots, 1$ (*backward*). O método aplicado do primeiro para o último período comporta-se como uma heurística gulosa, otimizando o problema dimensionamento e seqüenciamento dos lotes a cada período. Ele não constrói, por exemplo, estoques de antecipação, ou mesmo agrega lotes de produtos contaminantes, tornando algumas vezes o problema nos períodos finais infactível. Desta forma, os experimentos com o método *relax-and-fix* períodos foram realizados do último para o primeiro períodos. Para este método foi imposto um limite de tempo de 600 segundos para a resolução de cada passo, totalizando 1 hora para a resolução de toda a heurística. Desta forma, o tempo total apresentado na tabela 5.7 corresponde à soma do tempo da melhor solução encontrada a cada passo. Conforme esperado, os primeiros passos levam mais tempo para serem resolvidos, pois, embora o número de variáveis inteiras em cada passo seja fixo $\left(\frac{NS}{t}\right)$, o número total de variáveis nos primeiros passos é maior.

Comparando as soluções obtidas nos experimentos do método ‘*relax-and-fix* períodos

com as soluções obtidas pelo método *branch-and-bound*, verifica-se que em relação aos valores da função objetivo, o método *relax-and-fix* períodos obtém resultados melhores que o método *branch-and-bound* em dois experimentos (mesA e mes7) e resultados piores no experimento (mes3).

5.2.3.2 Abordagem ATSP

A tabela 5.8 apresenta os resultados obtidos nos experimentos com o modelo ATSP seqüências dependentes ((4.36)-(4.52)), incluindo o termo de penalização (4.1a) na função objetivo. São apresentados os seguintes resultados: função objetivo (em unidades monetárias); tempo total de processamento computacional (limitado em uma hora de processamento); número de iterações; e, o número de sub-rotas. Estes resultados correspondem aos experimentos resolvidos pelo método *branch-and-cut* com eliminação de sub-rotas e pelo método de combinação e eliminação de sub-rotas (*patching*), apresentados no capítulo anterior (seção 4.3.3).

	eliminação de sub-rotas					<i>patching</i>				
	f.o.	tempo	iterações	sub-rotas	gap (%)	f.o.	tempo	iterações	sub-rotas	gap (%)
mesA	3445	2374	63	267	0	3445	9	1	5	0
mesB	16616	0,93	3	15	0	16616	9	1	9	0
mes1	4312	643	61	333	0	4312	472	1	7	0
mes2	8176	1098	62	369	0	8176	196	1	5	0
mes3	4281	273	176	766	0	4281	279	1	8	0
mes4	3378	264	106	499	0	3378	1	1	5	0
mes5	13510	3600	61	299	0,07	13510	4	1	6	0
mes6	10019	1082	48	250	0	10019	2	1	5	0
mes7	10237	848	81	405	0	10237	7	1	7	0
média	8219	1131	73	356	0,01	8219	109	1	6	0

Note na tabela 5.8 que, para os exemplares resolvidos pelo método eliminação de sub-rotas, os valores ótimos do problema são encontrados e provados em todos os experimentos, exceto para o exemplar mes5. Em relação ao desempenho computacional, os resultados variam muito de um exemplar para outro, mas em média são resolvidos em 1131 segundos. Os exemplares que levam mais tempo para serem resolvidos pelo modelo ATSP

seqüências dependentes e método de eliminação de sub-rotas são: mesA, mes2, mes5 e mes6. Uma observação interessante é que, na tabela 5.4, os exemplares mesA, mes2 e mes5 tem mais produtos contaminantes, de grau 3 e grau 4, sendo demandados.

Já nos experimentos com o método que combina eliminação e combinação de sub-rotas (*patching*), os valores da função objetivo são encontrados em tempos computacionais razoáveis, entre 1 segundo (por exemplo, mes4) e 472 segundos (mes1). Para todos os exemplares testados, este método encontra a solução ótima em uma iteração, sendo que são encontradas em média apenas 6 sub-rotas.

Podemos observar na tabela 5.8 que os tempos computacionais dos dois métodos de solução não são correlacionados. Ou seja, instâncias que demandam os maiores tempos no método ‘eliminação de sub-rotas’, como mesA e mes5, não necessariamente demandam o maior tempo no método *patching*.

5.2.3.3 Comparação entre abordagens GLSP e ATSP seqüências dependentes

A tabela 5.9 agrupa e resume os resultados obtidos para as abordagens em que o seqüenciamento considera períodos dependentes. A linha superior corresponde ao valor da função objetivo e a linha inferior corresponde ao tempo computacional, em segundos, no qual a solução foi obtida. Vale lembrar que, os tempos computacionais dos experimentos GLSP são diferentes dos tempos computacionais dos experimentos ATSP. Em ambos o tempo total para execução foi limitado em 3600 segundos, nos experimentos ATSP a solução ótima geralmente é encontrada antes do tempo limite (com exceção do mes5 na abordagem ATSP com eliminação de sub-rotas), enquanto que nos experimentos GLSP a solução encontrada não tem garantia de otimalidade, mesmo depois de uma hora de execução. Ou seja, a execução do experimento é interrompida por atingir o limite de tempo. Os melhores resultados da função objetivo e tempo computacional estão destacados (em negrito) na tabela 5.9.

Observe nestes experimentos que as diferenças em relação aos valores obtidos para a função objetivo não são significantes de uma abordagem para outra, sendo que para os dados mesB, mes1, mes2, mes4, mes5 e mes6, a solução obtida é a mesma. Por outro lado, os tempos computacionais são bem distintos. Em geral a abordagem ATSP-*patching* é bem mais rápida, obtendo a solução em tempo bem menor em seis dos nove experimentos. Em média, o tempo computacional da abordagem ATSP-*patching* é 108 segundos, enquanto que o tempo

médio do modelo ATSP com o método eliminação de sub-rotas é 1131 segundos. As soluções GLSP, algumas vezes são obtidas depois de pouco tempo computacional, por exemplo, a abordagem GLSP *relax-and-fix* variáveis tem tempo médio de 329 segundos. Entretanto, estas soluções não são ótimas, mesmo depois de uma hora de processamento.

Tabela 5.9 Resultados das abordagens para a estratégia Sequências Dependentes.					
	GLSP	GLSP- RFvariáveis	GLSP- RFperiodos	ATSP- sub- rotas	ATSP- <i>patching</i>
mesA	3519	3453	3445	3445	3445
	(360 / 3600)	(1273 / 3600)	(415 / 3600)	(2374)	(9)
mesB	16616	16616	16616	16616	16616
	(157 / 3600)	(150 / 3600)	(511 / 3600)	(0,93)	(0,35)
mes1	4312	4312	4312	4312	4312
	(339 / 3600)	(132 / 3600)	(115 / 3600)	(643)	(472)
mes2	8176	8176	8176	8176	8176
	(438 / 3600)	(258 / 3600)	(65 / 3600)	(1098)	(196)
mes3	4328	4328	4589	4281	4281
	(1049 / 3600)	(240 / 3600)	(243 / 3600)	(273)	(279)
mes4	3378	3378	3378	3378	3378
	(2854 / 3600)	(183 / 3600)	(2150 / 3600)	(264)	(1)
mes5	13510	13510	13510	13510	13510
	(775 / 3600)	(117 / 3600)	(341 / 3600)	(3600)	(4)
mes6	10019	10019	10019	10019	10019
	(345 / 3600)	(128 / 3600)	(227 / 3600)	(1082)	(2)
mes7	11597	10726	10851	10237	10237
	(2998/3600)	(484 / 3600)	(1506 / 3600)	(848)	(7)
média	8384	8280	8322	8219	8219
	1035 / 3600	(329 / 3600)	(619 / 3600)	(1131)	(108)

A figura 5.10 apresenta uma comparação entre as soluções encontradas nas diferentes abordagens, por meio do *gap* médio de otimalidade. Note que este *gap* de otimalidade não é o mesmo apresentado na tabela 5.7, este valor foi calculado a partir da solução ótima encontrada pelas abordagens ATSP, e não pelo limitante inferior calculado no *branch-and-cut*.




Figura 5.10 – *Gaps* relativos médios dos modelos/ métodos para a estratégia Seqüências Dependentes.

Um resumo dos programas de produção resultantes para a abordagem com seqüenciamento dependente entre os períodos encontra-se na tabela 5.10. Para todos os conjuntos de dados são apresentados: a capacidade utilizada em cada período (em porcentagem); as horas extras necessárias em cada período e o número de preparações ou limpezas necessárias para evitar a contaminação cruzada dentro do período.

Tabela 5.10 Resultados da solução - Seqüências Dependentes.

Dados	Capacidade utilizada				Horas Extras				Preparação			
	$t=1$	$t=2$	$t=3$	$t=4$	$t=1$	$t=2$	$t=3$	$t=4$	$t=1$	$t=2$	$t=3$	$t=4$
mesA	96	100	100	100	0	0	0	0	1	1	0	0
mesB	100.1	104.7	125	93.5	0.07	3	16	0	1	0	0	1
mes1	94.2	99.9	100	100.2	0	0	0	0.1	0	1	0	0
mes2	100.1	100	100	106	0.04	0	0	3.1	2	0	0	0
mes3	97	99.4	100	97.4	0	0	0	0	1	0	0	1
mes4	73.1	79.1	94.9	99.8	0	0	0	0	0	1	1	0
mes5	99.8	100	100	119.2	0	0	0	10	1	0	0	0
mes6	99.9	100	100	111	0	0	0	5.7	1	0	0	0
mes7	100.2	100.6	100	121.9	0.07	0.27	0	9.2	1	1	0	0

Conforme esperado, quando a capacidade é restritiva, o número de preparações tende a ser minimizado pelo modelo. As abordagens, sempre que possível, agrupam a demanda dos produtos com maior grau de contaminação em lotes maiores, diminuindo a necessidade de limpezas adicionais. No entanto, esta decisão depende de vários fatores: a distribuição da demanda entre os períodos; a capacidade disponível para agrupar lotes de

famílias de produtos com maior grau de contaminação, bem como a viabilidade de custos resultante (estocagem); e, a quantidade de famílias críticas para o seqüenciamento. Em todos os programas de produção resultantes, a demanda é atendida sem atrasos. A análise detalhada dos programas de produção obtidos nos experimentos realizados mostra que existem algumas características comuns no seqüenciamento, como, por exemplo, o produto final na seqüência de um determinado período geralmente é o produto inicial na seqüência do próximo período.

5.2.4 Comparação entre estratégias seqüências dependentes e seqüências independentes

Conforme apresentado no capítulo 4, a empresa estudada tem como prática a realização da limpeza semanal, durante o período de produção, apenas nos períodos de maior ociosidade. Ou seja, esta prática é ocasional, a estratégia realmente adotada é a estratégia seqüências dependentes. No entanto, devido à tendência crescente de preocupações com a segurança alimentar, a empresa considera a possibilidade de realizar uma limpeza semanal. Uma questão relacionada a esta estratégia é determinar se a limpeza será feita durante o período de produção, reduzindo a capacidade do período, ou se a limpeza será feita fora do período de produção (por exemplo, no final de semana), implicando eventualmente em custos extras.

Desta forma, para verificar os impactos nos custos são analisadas as seguintes estratégias: Seqüências Independentes com redução da capacidade disponível para produção no tempo equivalente a uma preparação em cada período (1,67 horas); Seqüências Independentes sem redução da capacidade; e, Seqüências Dependentes. Os resultados destes experimentos encontram-se na tabela 5.11, e correspondem aos valores ótimos das abordagens ATSP. O modelo ATSP seqüências independentes, com e sem redução de capacidade, foi resolvido pelo método ‘eliminação de sub-rotas’. O modelo ATSP seqüências dependentes foi resolvido pelo método de eliminação e combinação de sub-rotas (*patching*).

Note que, para a estratégia seqüências independentes com redução de capacidade os valores da função objetivo sempre resultam em custos maiores. Embora a limpeza semanal reduza o número de preparações necessárias, a redução de capacidade nos períodos implica no aumento dos custos de horas extras e estocagem. Para o exemplar mesB, por exemplo, com a redução de capacidade na estratégia seqüências independentes, não é possível encontrar uma solução factível dentro do limite de tempo de uma hora.

Tabela 5.11 Comparação entre estratégias relacionadas à limpeza.

	seqüências independentes sem redução capacidade		seqüências dependentes		seqüências independentes capacidade reduzida	
	f.o.	tempo	f.o.	tempo	f.o.	tempo
mesA	3028	336	3445	9	4855	508
mesB	15425	9	16616	0,35	-	-
mes1	4023	3542	4312	472	6512	3600
mes2	7655	2011	8176	196	11392	3600
mes3	3207	460	4281	279	7050	657
mes4	3378	104	3378	1	6514	35
mes5	13056	43	13510	4	16872	3600
mes6	9611	399	10019	2	13336	962
mes7	9076	3600	10237	7	13454	3600
média	7607	1167	8219	108	9998	2070

Para a estratégia seqüências independentes sem redução de capacidade, os valores da função objetivo são, em média, 7,45% menores em relação à estratégia seqüências dependentes. Esta diferença é explicada pelo fato de que, na estratégia seqüências independentes sem redução de capacidade, a limpeza no final de cada período diminui a necessidade de preparações que impactam no consumo de capacidade.

A figura 5.11 ilustra as seguintes diferenças no programa de produção gerado pelas três estratégias: consumo médio de capacidade em cada período; total de horas extras utilizadas em todos os períodos; número total de preparações necessárias em todos os períodos. Estes valores correspondem às médias de todos os exemplares reais.

Note na figura 5.11 que, a estratégia de usar a capacidade do período para a limpeza semanal (seqüências ind. capacidade reduzida), impacta significativamente na utilização média de capacidade e necessidade de horas extras. Nesta estratégia o consumo médio de capacidade do programa de produção resultante é de 117%, e são necessárias 82 horas extras em todo horizonte de planejamento.

O consumo médio de capacidade e o total de horas extras variam pouco entre as estratégias seqüências independentes sem redução de capacidade e seqüências dependentes (figura 5.11).




Figura 5.11 – Comparação dos programas de produção resultantes para as três estratégias de limpeza semanal.

Quanto à necessidade de preparações, na estratégia seqüências dependentes são necessárias 15 preparações, enquanto nas estratégias seqüências independentes com e sem redução de capacidade são necessárias 2 e 3 preparações, respectivamente. Na verdade, como são realizadas preparações ao final de todo período, nas estratégias seqüências independentes são realizadas mais 4 preparações para cada exemplar, totalizando 38 e 39 preparações.

Vale lembrar que a comparação entre estas estratégias não é direta, pois envolvem diferentes pressupostos. Por exemplo, na estratégia seqüências independentes sem redução de capacidade, não foram considerados os prováveis custos extras da limpeza semanal.

No entanto, os resultados dos experimentos com dados reais, explorando as possíveis estratégias de limpeza semanal, mostram que, se a empresa adotar a limpeza semanal dentro do período de produção, o impacto nos custos é significativo. Além disso, os custos de oportunidade devem ser adequadamente avaliados, pois a limpeza consome grande parte da capacidade produtiva.

5.2.5 Comparação com os Resultados da Empresa

Não foi possível obter os resultados da empresa para todo o conjunto de dados coletados. Somente para o experimento mesA, os resultados reais praticados pela empresa foram fornecidos em detalhes. Desta forma, a solução da empresa para os demais

experimentos foi calculada, considerando que o programa de produção da empresa é feito com base na estratégia de acompanhar a demanda a cada período (*chase strategy*), e considerando que atualmente não é feita a limpeza semanal na linha (estratégia seqüências dependentes). Os resultados obtidos referem-se aos custos de horas extras necessárias para o dimensionamento lote por lote. Vale ressaltar que não foram considerados custos resultantes dos tempos de preparação. Esta estratégia da empresa resulta em custos substancialmente maiores, em relação aos obtidos pelas abordagens anteriores, conforme pode ser observado na figura 5.12.




Figura 5.12 – Comparação entre a solução ótima gerada (estratégia Seqüências Dependentes) com a solução praticada pela empresa.

Nas soluções ótimas, além de antecipar a produção nos períodos onde existe capacidade ociosa, ainda são encontradas seqüências de produção melhores, com menos preparações. Cabe salientar que o programa de produção da empresa é cauteloso em relação a aumentos de demanda previstos para o final do mês, ou seja, a programação da empresa aposta que estes aumentos podem não ocorrer. Se isto acontecer de fato, a estratégia de produção da empresa pode ser melhor do que parece. Entretanto, esta cautela da empresa em relação às incertezas da demanda pode ser contemplada nas abordagens anteriores, por meio de análise de sensibilidade, alterando-se os parâmetros de demanda por valores menos otimistas e executando-se o programa para diversos cenários.

5.2.6 Detalhamento do programa de produção ótimo para o mesA

A tabela 5.12 apresenta o plano de produção para o mesA, gerado pelo modelo GLSP com o método *relax-and-fix* períodos. Este plano de produção inclui: o dimensionamento dos lotes, quantidade a ser produzida em cada período; e o seqüenciamento, ordem em que os lotes devem ser produzidos. Na tabela também são apresentados: o tempo total para produção em cada período; o tempo total de preparações; a capacidade utilizada; e, a quantidade de horas extras necessárias.

ordem	$t = 1$		$t = 2$		$t = 3$		$t = 4$	
	produto	quantidade	produto	quantidade	produto	quantidade	produto	quantidade
1	fam17	10	fam20	5	fam21	65	fam2	1
2	fam5	25	preparação		fam3	9	fam17	3
3	fam3	9	fam10	57	fam11	6	fam21	14
4	fam11	2	fam3	16	fam14	20	fam14	19
5	fam19	2	fam14	15	fam4	1	fam3	25
6	preparação		fam17	3	fam5	2	fam13	1
7	fam17	10	fam8	29	fam13	1	fam8	52
8	fam9	40	fam7	16	fam8	32	fam9	50
9	fam15	2	fam12	1	fam12	1	fam7	11
10	fam16	1	fam9	34	fam17	3	fam10	79
11	fam8	29	fam5	15	fam9	32	fam5	5
12	fam12	2	fam13	1	fam10	65	fam11	5
13	fam10	58	fam11	6	fam7	12	fam19	4
14	fam2	2	fam20	5	fam2	9		
15	fam21	38	fam21	49				
16	fam14	12						
17	fam20	4						
T. Produção	59,8		62,3		64		64	
T. Preparação	1,67		1,67		0		0	
Cap. Utilizada	61,47		63,97		64		64	
Horas Extras	0		0		0		0	

Conforme podemos observar na tabela 5.12, no primeiro período ($t=1$) a demanda é completamente atendida, e ainda são produzidas para estoque: 1 batelada da família 15; 2 bateladas da família 19; e, 3 da família 21. Para produzir a seqüência gerada pelo modelo é necessário fazer uma preparação neste período, entre as famílias 19 e 17. O tempo necessário para produção é de 59,8 horas, totalizando uma capacidade utilizada de 96% da capacidade disponível.

No segundo período ($t=2$) a demanda é atendida totalmente pelas quantidades produzidas, exceto pelas famílias 15 e 19 que são atendidas pelo estoque do período t1. Neste

período ainda é prevista a produção para estoque de 2 bateladas da família 9, 5 bateladas da família 20 e 14 da família 21. Na tabela 5.12 vemos que a seqüência deste período necessita de apenas uma preparação, resultando em um tempo total de 63,97 horas.

No terceiro período ($t=3$) o plano de produção gerado atende completamente a demanda do período, exceto pela família 19 que utiliza 1 batelada do estoque, e pela família 20 que utiliza 4 bateladas produzidas anteriormente. Ainda são programadas a produção de 19 bateladas de estoque para a família 21. Para produzir a seqüência planejada para este período não é preciso realizar nenhuma preparação (tabela 5.12), portanto a capacidade de tempo necessária é de 64 horas, que corresponde a 100% da capacidade disponível.

Finalmente, no quarto período, onde a demanda prevista é superior à capacidade produtiva do período, a demanda é atendida pelas quantidades produzidas mais 1 batelada estocada da família 20, 2 bateladas da família 9 e 33 bateladas em estoque da família 21. Da mesma maneira que no período anterior a produção é seqüenciada de forma que não é necessário realizar nenhuma preparação. O tempo total para produção também é de 64 horas.

Observe que, como a capacidade de cada período é de 64 horas de produção, não são utilizadas horas extras em nenhum período. Isto implica que o custo resultante deste plano de produção (3445 u.m.) corresponde apenas aos custos de manter estoques. Note na tabela 5.12, na seqüência de produção resultante que algumas famílias exercem a função de 'limpante', como por exemplo, a seqüência 'fam14-fam17-fam8' no período $t=2$. Isto ocorre porque a desigualdade triangular não é válida para o problema em questão. Neste caso, para produzir a família 8 depois da família 14 é necessário fazer uma limpeza (tabela A3 do apêndice A), produzindo um lote da família 17, entre as famílias 14 e 8, a limpeza na linha se torna desnecessária.

5.3 Experimentos com alteração nos parâmetros

Para melhor avaliar o desempenho das abordagens propostas, foram realizados diversos experimentos com geração de dados aleatórios e/ou com perturbações nos dados coletados no estudo de caso. Estes experimentos foram norteados por dois objetivos distintos.

O primeiro consiste em verificar como algumas variações nos dados reais (fornecidos pela empresa) impactam nas soluções dos diferentes modelos e métodos; este objetivo está diretamente relacionado à aplicabilidade das abordagens. Desta forma, foram realizados testes alterando-se os seguintes parâmetros reais: custos de estocagem (teste 1); capacidade (teste 2); e, demanda (teste 3).

O segundo objetivo consiste em explorar as características dos modelos desenvolvidos para o problema de dimensionamento e seqüenciamento de lotes na indústria de suplementos, que apresenta algumas singularidades, como a estrutura da matriz de tempos de preparação e a condição de integralidade das variáveis de dimensionamento de lotes. Desta forma, foram realizados experimentos alterando-se: a definição de tipo da variável (q_{is}) (teste 4); e, a matriz de tempos de preparação (st_{jis}) (teste 5).

5.3.1 Teste 1: alteração no *trade-off* de custos

Nos resultados dos experimentos realizados com dados reais, observamos que os custos de estocagem são relativamente pequenos em relação aos custos de horas extras. Ou seja, nos planos de produção gerados alternativa de estocar é preferida, como pode ser observado na figura 5.13, para os exemplares mesA, mes1, mes2, mes3 e mes4. Como resultado, as soluções geradas pelos modelos tendem a priorizar a alternativa de estocar de um período para outro. Conforme pode ser observado na figura 5.13, que mostra a relação entre os custos de estocagem e horas extras na solução ótima do problema para a estratégia seqüências dependentes para todas as instâncias reais.




Figura 5.13 – Gráfico ilustrando a relação entre os custos de estocagem e horas extras da solução ótima da estratégia Seqüências Dependentes.

No entanto, a empresa aposta na estratégia de acompanhar a demanda, incorrendo sempre que necessário na utilização de horas extras. Um fator que pode explicar

certa inconsistência nos custos de estocagem calculados e fornecidos pela empresa é a dificuldade de quantificar os riscos associados à estocagem dos produtos.

Para avaliar o desempenho dos modelos diante de outras relações entre os custos e analisar melhor a estratégia de produção da empresa, foram realizados diversos experimentos aumentando-se gradativamente os custos de estocagem. Estes foram aumentados até se obter valores onde a solução obtida pelos modelos se aproxime da solução praticada na empresa. Por conveniência, estes experimentos foram realizados com os exemplares mesA, mes3 e mes7. Para estes exemplares, nos experimentos anteriores nem todas as abordagens encontram a solução ótima (conforme tabela 5.9), além disso, o mesA e mes7 apresentam diferenças no *trade-off* entre os custos na solução ótima (figura 5.13).

Os custos foram gradativamente aumentados em 10, 50, 100, 200, 400 e 800 por cento. Uma tabela completa com todos os resultados encontra-se no Anexo C. A figura 5.14 apresenta um gráfico com a proporção média entre os custos de estocagem e os custos de horas extras gerados para os três exemplares. Note nesta figura que, sem aumentar os custos de estocagem (0%), em média 64% do valor da função objetivo correspondem ao valor dos custos de estocagem. Aumentando-se os custos de estocagem por produto (h_i) em 10% e 50%, diminui a proporção destes na função objetivo, e a relação entre custos de estocagem e custos de horas extras na solução ótima fica equilibrada. Vale lembrar que a opção de estocar também é limitada pela disponibilidade de capacidade nos períodos. Por exemplo, no exemplar mes7 a capacidade necessária somente para produção no período $t=4$ é 132% (tabela 5.4), ainda que a produção seja antecipada, a folga de capacidade nos demais períodos não é suficiente, o que implica na utilização de horas extras. Conforme o custo de estocagem é aumentado, diminui sua proporção nos valores médios da função objetivo.

Note na figura 5.14 que, somente quando os custos de estocagem são substancialmente aumentados é que os valores médios obtidos pelo modelo se aproximam da estratégia adotada pela empresa, isto é, a utilização de horas extras passa a ser a melhor alternativa para equilibrar demanda e capacidade.




Figura 5.14 – Gráfico ilustrando o *trade-off* médio entre custos de estocagem e de horas conforme aumenta-se os custos de estocagem.

Outros aspectos interessantes observados nos resultados destes experimentos estão relacionados ao comportamento das diferentes abordagens. Para a estratégia seqüências dependentes, os melhores resultados foram obtidos por meio das abordagens ATSP, que encontram a solução ótima em todos os experimentos. Entretanto, o método de solução com combinação e eliminação de sub-rotas (*patching*) é muito mais rápido, com tempo computacional médio de 110 segundos, enquanto para o método com eliminação de sub-rotas, o tempo médio é de 2400 segundos. Em relação à abordagem GLSP, o método mais eficiente foi o *relax-and-fix* variáveis, que obtém o melhor valor de função objetivo em 94% dos experimentos realizados.

Para a estratégia seqüências independentes, a abordagem ATSP encontra a solução ótima em todos os experimentos, enquanto a abordagem GLSP encontra a solução ótima em apenas metade dos experimentos. Quanto ao tempo computacional, a abordagem ATSP é cerca de 45% mais rápida (tabela Anexo C).

Em resumo, os resultados destes experimentos mostram que, a alteração na relação entre os custos de estocagem e horas extras não afeta significativamente o desempenho das abordagens propostas.

5.3.2 Teste 2: alteração na capacidade produtiva

Com o objetivo de verificar o desempenho dos modelos e métodos diante de cenários de capacidade mais restritiva, foram realizados experimentos diminuindo-se a capacidade produtiva em 10 e 20%, de maneira que a distribuição de capacidade nos períodos não seja alterada, isto é, em todos os períodos a capacidade é igualmente reduzida. Para todos os outros parâmetros foram mantidos os valores coletados na empresa. Experimentos que alteram a distribuição de capacidade ao longo dos períodos são contemplados em outros experimentos (conforme mostrado adiante), onde são geradas demandas aleatórias.

Novamente os exemplares utilizados nestes experimentos são mesA, mes3 e mes7. As tabelas com resultados completos destes experimentos encontram-se no Anexo C. O gráfico na figura 5.15 compara os valores da função objetivo para os dados reais e com a redução de capacidade em 10 e 20%. Todos os valores estão em porcentagem, o valor da função objetivo do problema real corresponde a 100%, em cada exemplar, enquanto os valores com redução de capacidade correspondem aos valores percentuais com redução de capacidade.




Figura 5.15 – Impacto da redução de capacidade sobre os valores ótimos da função objetivo.

A redução da capacidade tem impacto direto nos custos, principalmente nos custos de horas extras, já que comprometem o tempo para produção em todos os períodos. Observe na figura 5.15 que os custos aumentam substancialmente, por exemplo, para o mesA, os custos aumentam cerca de 6 vezes quando a capacidade é reduzida em 10%, e cerca de 12 vezes quando a capacidade é reduzida em 20%.

Outra questão importante a ser avaliada em cenários de capacidade mais restritiva é o desempenho dos diferentes modelos e métodos para encontrar a solução. Neste sentido,

calculamos a média do *gap* de otimalidade dos três exemplares testados (mesA, mes3, mes7). A figura 5.16 apresenta a variação do *gap* médio de otimalidade com a redução de capacidade para cada uma das abordagens propostas. Note nesta figura que, nas abordagens GLSP, exceto para a estratégia seqüências independentes (GLSP períodos), os valores do *gap* de otimalidade diminuem conforme a capacidade é reduzida. Por exemplo, o valor do *gap* médio de otimalidade da abordagem GLSP *relax-and-fix* variáveis, é de quase 3% nos experimentos com dados reais, 0,25% nos experimentos com redução de 10% na capacidade, e 0% nos experimentos com redução de 20% na capacidade. Observe também na figura 5.16 que as abordagens ATSP sempre encontram a solução ótima.




Figura 5.16 – Impacto da redução de capacidade nos *gaps* de otimalidade.

Os tempos computacionais nestes experimentos também variam bastante de uma abordagem para outra. Para a estratégia Seqüências Dependentes a abordagem ATSP *patching* é a mais rápida, resolvendo: o problema real em 102 segundos em média (mesA, mes3, mes7); o problema com 10% de redução de capacidade em 97 segundos em média; e, o problema com 20% de redução de capacidade em 2 segundos em média. Já os tempos médios da abordagem ATSP com eliminação de sub-rotas são mais altos: o problema real é resolvido em média em 1165 segundos, enquanto que os problemas com as reduções de 10 e 20% são resolvidos em 1104 e 1112 segundos, respectivamente. Em relação aos tempos computacionais das abordagens GLSP, os experimentos são executados até o limite de 1 hora, ou seja, como nos experimentos anteriores, as soluções não têm garantia de otimalidade. Todos os tempos computacionais dos experimentos com redução de capacidade encontram-se no anexo C.

Em resumo, estes experimentos (teste 2) mostram que o desempenho das

abordagens ATSP não é alterado para problemas com capacidade mais restritiva. No entanto, o desempenho das abordagens GLSP para a estratégia seqüências dependentes (GLSP *branch-and-cut*, GLSP *relax-and-fix* variáveis e GLSP *relax-and-fix* períodos) parece melhorar com a redução da capacidade, o que não era esperado.

5.3.3 Teste 3: alterações na demanda

Conforme mencionado no capítulo 2, a demanda por produtos na indústria de suplementos para nutrição animal tem algumas peculiaridades relevantes, por exemplo, o *mix* de produtos varia muito de um período para o outro, bem como a quantidade demandada. Alguns produtos são demandados em pequenas quantidades (1 ou 2 bateladas) em todos os períodos, enquanto outros demandam mais de 200 bateladas (conforme tabela 4 do anexo A). Desta forma, o objetivo nestes experimentos é testar diferentes configurações de demanda.

Primeiramente, os dados coletados de demanda (instâncias reais) foram concentrados no final do último período. Assim, podemos analisar o impacto nos custos se, por exemplo, a empresa adotar a estratégia de produção para estoque (*make-to-stock*), como alternativa ao planejamento com base na demanda mensal e desdobramento semanal. A figura 5.17 mostra o efeito nos valores ótimos da função objetivo encontrados.

Pela figura 5.17 podemos observar que os custos totais aumentam substancialmente. Este aumento ocorre principalmente pelo aumento nos custos de estocagem, pois para atender a demanda no período $t=4$, a produção deve ser antecipada. Por exemplo, para o mesA, 99,87% do custo total corresponde aos custos de estocagem, enquanto a utilização de horas extras é pouco relevante (tabela Anexo C). Em relação à qualidade das soluções obtidas, todas as abordagens encontram a solução ótima para todas as instâncias, mas, como nos experimentos anteriores, as soluções das abordagens GLSP não têm garantia de otimalidade dentro do limite de tempo de 1 hora de execução. Os tempos computacionais em que as soluções são obtidas variam de um experimento para outro, mas, em média, os experimentos com a demanda concentrada são 63,8% mais rápidos.




Figura 5.17 – Efeito da concentração da demanda nos valores ótimos da função objetivo.

Para explorar outras variações na demanda foram realizados experimentos com geração de dados aleatórios. Em um primeiro momento foram gerados valores uniformemente distribuídos dentro do intervalo de demanda real mínima e máxima de cada produto. Por exemplo, pela tabela 4 do anexo A, sabemos que a demanda mínima para o produto fam10 são 14 bateladas (exemplar mes1, período $t=2$) e a demanda máxima são 88 bateladas (exemplar mes2, período $t=4$). Assim, em cada período, foram gerados valores uniformemente distribuídos entre 14 e 88 para o produto fam10. Os valores de demanda gerados foram aproximados para valores inteiros. Da mesma maneira, foram geradas novas demandas para todos os produtos. Desta forma, são mantidas as características do problema da indústria de suplementos, alterando apenas a distribuição de demanda dos produtos entre os períodos.

Um inconveniente ao gerar dados de demanda aleatórios é que a capacidade necessária para produção pode ser muito alta em relação à capacidade disponível, gerando instâncias infactíveis. Para atenuar este problema, depois de gerados novos valores de demanda por período (d_{it}), calculamos a capacidade necessária para produção em cada período ($d_{it} * p_i$), e, geramos novos limites de capacidade por período (C_t), uniformemente distribuídos entre 80 e 120% do valor encontrado para a capacidade necessária. Cabe ressaltar que esta oscilação de demanda entre 80 e 120% da capacidade produtiva também é observada na prática.

A disponibilidade de horas extras (u_t) também foi recalculada para manter uma coerência com a capacidade disponível. Neste sentido, os novos valores para u_t correspondem a 25% do valor gerado para a capacidade, garantindo que as instâncias geradas tenham solução factível.

Nestes experimentos com variação de demanda, todos os demais parâmetros:

custos de horas extras (co_i), custos de estocagem (h_i), tempos de produção (p_i) e tempos de preparação (st_{ji}) correspondem aos valores reais. Desta forma, foram geradas cinco instâncias que foram testadas com todas as abordagens propostas no capítulo 4. Os resultados completos destes experimentos encontram-se no Anexo C.

Em geral, o comportamento das diferentes abordagens nos experimentos com geração de demanda aleatória (dentro dos limites mínimo e máximo das demandas reais) não difere muito em relação aos experimentos com dados reais. A figura 5.18 mostra os valores médios dos *gaps* relativos, calculados separadamente para as duas estratégias: seqüências dependentes e independentes. Cabe ressaltar que estes *gaps* relativos são diferentes dos *gaps* de otimalidade definidos no início da seção 5.2, na medida em que estes comparam os valores de função objetivo entre si.




Figura 5.18 Valor médio dos *gaps* relativos das soluções encontradas pelas diferentes abordagens.

Note na figura 5.18 que, em geral as abordagens ATSP apresentam os melhores resultados. Observe que, diferentemente dos experimentos com dados reais, o valor do *gap* relativo para a abordagem ATSP com eliminação de sub-rotas é 0,9%, o que indica que esta abordagem não encontra a solução ótima para todas as instâncias dentro do limite de tempo. Uma questão relevante quando as abordagens ATSP não encontram a solução ótima no limite de tempo é que a solução MIP truncado obtida pode não ser factível do ponto de vista do seqüenciamento de lotes, ou seja, a seqüência nesta solução pode conter sub-rotas. Nestes experimentos, as seqüências obtidas foram verificadas, e as soluções são factíveis.

Em relação ao desempenho computacional, as abordagens aplicadas ao problema com seqüências dependentes, em média, requerem maior tempo de resolução para os experimentos com dados aleatórios, exceto a abordagem ATSP com combinação e eliminação de sub-rotas (figura 5.19). Já nas abordagens propostas para o problema com seqüências independentes, o tempo médio de resolução das instâncias com demanda aleatória

é menor.




Figura 5.19. Comparação entre tempos computacionais médios dados: reais x aleatórios.

Conforme mencionado, os experimentos com demanda gerada dentro dos limites de demanda real mínima e máxima, preservam os padrões de demanda da empresa. Nos dados reais fornecidos pela empresa, observamos que a demanda média por produtos varia entre 0 e 46 bateladas (tabela 4 do anexo A). Para testar o desempenho das abordagens GLSP e ATSP em situações de demanda mais gerais, geramos valores de demanda uniformemente distribuídos entre 0 e 50 para todos os produtos. Apesar do intervalo dos dados aleatórios ser próximo dos valores médios reais, existe uma diferença significativa no *mix* de produtos gerados em relação aos dados reais, e aos dados gerados dentro dos limites mínimo e máximo: os valores de demanda para todos os produtos são gerados no mesmo intervalo. Por exemplo, tanto a demanda de um produto mais contaminante, como a demanda de um produto menos contaminante tem igual probabilidade de ocorrer. Como nos experimentos anteriores, os valores de demanda gerados foram aproximados para inteiros. Para contornar os problemas de restrição de capacidade, usamos as mesmas estratégias do experimento anterior e recalculamos a capacidade produtiva (C_t) e os limites de horas extras (co_t) em cada período. Desta forma, foram geradas 10 instâncias, que foram testadas para todas as abordagens. Os resultados completos destes experimentos encontram-se no Anexo C.

A figura 5.20 mostra os *gaps* relativos médios para todas as abordagens analisadas. Para a estratégia seqüências dependentes, podemos observar que as abordagens ATSP são melhores, obtendo as soluções ótimas em quase todas as instâncias geradas. A abordagem GLSP *relax-and-fix* variáveis (GLSP RF variáveis) apresenta bons resultados, encontrando soluções muito próximas dos valores ótimos. Para a estratégia seqüências independentes,

ambas as abordagens ATSP e GLSP encontram valores ótimos em todas as instâncias.




Figura 5.20 Comparação entre *gaps* relativos das soluções com demanda aleatória U (0,50).

Quanto aos tempos de processamento computacional, a abordagem ATSP *patching* em média encontra as soluções mais rapidamente. Mas, comparando-se com os tempos de solução das instâncias reais, o tempo médio aumenta de 98 para 1488 segundos (conforme pode ser observado na figura 5.21). Existe muita diferença de uma abordagem para a outra, e também, considerando uma mesma abordagem, existe muita variação de uma instância para outra. Por exemplo, na abordagem ATSP *patching*, uma instância é resolvida em 2 segundos, enquanto quatro instâncias não são resolvidas otimamente dentro do limite de tempo de uma hora.




Figura 5.21 Comparação dos tempos computacionais médios: demanda aleatória U (0,50).

As instâncias geradas para estes experimentos são mais difíceis, na medida em que a probabilidade de ocorrência de demanda por produtos mais contaminantes é a mesma que a de produtos menos contaminantes. Neste sentido, podemos observar que as soluções

geradas por estes experimentos apresentam um maior tempo médio de preparações, conforme apontado na figura 5.22.




Figura 5.22. Comparação dos tempos médios de preparação: dados reais x dados aleatórios.

Em resumo, os experimentos com alteração nos dados de demanda (teste 3) mostram que, o desempenho das abordagens ATSP são menos sensíveis à variação na demanda. Nestes experimentos, a melhor abordagem para a estratégia seqüências dependentes é a abordagem ATSP *patching*, que encontra os valores ótimos para todas as instâncias em tempo computacional razoavelmente rápido. Os piores desempenhos foram das abordagens GLSP *branch-and-cut* e GLSP *relax-and-fix* períodos (figuras 5.18 e 5.20).

5.3.4 Teste 4: relaxação da integralidade das variáveis de dimensionamento de lote

Um dos diferenciais do problema tratado neste trabalho é a condição de integralidade das variáveis que determinam a quantidade a ser produzida em cada período (q_{is} nos modelos GLSP; q_{it} nos modelos ATSP). Geralmente, problemas com maior número de variáveis inteiras são mais difíceis de resolver. Para verificar se esta condição tem impacto significativo no desempenho das abordagens de solução, foram realizados experimentos com os dados reais relaxando esta condição (resultados no Anexo C). Vale lembrar que para a abordagem GLSP *relax-and-fix* variáveis, este experimento não faz sentido.

A figura 5.23 compara os valores médios dos *gaps* relativos para os experimentos com a variável de dimensionamento de lotes inteira e para o experimento relaxado. Conforme esperado, os valores da função objetivo nos experimentos com a variável q_{is} relaxada, são melhores do que os valores com q_{is} inteira. A única exceção foram os resultados da abordagem GLSP períodos, onde o *gap* relativo médio para problema relaxado é 3,23%,

enquanto o *gap* relativo médio para o problema com q_{is} inteira foi de 0,03%. Novamente as abordagens ATSP encontram as soluções ótimas em todos os experimentos.




Figura 5.23 Comparação entre tempos médios de preparação nos experimentos com dados reais e com dados aleatórios.

Quanto aos tempos computacionais, o desempenho da abordagem ATSP *patching* é melhor, as soluções são encontradas mais rapidamente em todas as instâncias. Para comparar o tempo computacional entre os experimentos com q_{is} positiva e q_{is} inteira, calculamos a média dos tempos de todas as abordagens em todas as instâncias (a partir dos dados de tempo disponíveis no anexo C). O tempo médio dos experimentos com q_{is} inteira é 1179 segundos, enquanto o tempo médio com q_{is} positiva é 599 segundos.

Em resumo, a relaxação da condição de integralidade das variáveis q_{is} (ou q_{it}) (teste 4) não altera de forma significativa a qualidade das soluções obtidas. Entretanto, os tempos computacionais são sensivelmente reduzidos.

5.3.5 Teste 5: alterações na matriz de tempos de preparação

A matriz de tempos de preparação da indústria de suplementos tem as seguintes características: não obedece a desigualdade triangular, é assimétrica e, no caso da empresa estudo de caso, também é esparsa. Conforme tabela 1 do anexo A, apenas 25,3% dos tempos de preparação (st_{ji}) são positivos. Para completar a análise sobre o desempenho dos modelos e métodos propostos, foram realizados alguns experimentos alterando a matriz de tempos de preparação.

Primeiramente, incluímos na matriz real os tempos (inicialmente desprezados) que

existem entre toda troca de produtos, isto é, substituímos os valores zero na matriz de preparação por 10 minutos (ou 0,1667 horas). Todos os outros parâmetros dos modelos foram mantidos, exceto os limites de horas extras, que foram aumentados para garantir que existam soluções factíveis.

Nestes experimentos, as soluções encontradas por todas as abordagens pioram significativamente; nenhuma das abordagens encontra a solução ótima para nenhuma das instâncias dentro do limite de tempo. A tabela 5.13 abaixo apresenta um resumo dos resultados factíveis da função objetivo nas diferentes abordagens e instâncias.

	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
GLSP	-	30807	-	-	32221	15232	-	-	-
GLSP RF variáveis	-	-	-	-	-	-	-	-	-
GLSP RF períodos	-	-	-	-	-	-	-	-	-
ATSP sub-rotas	-	20785	-	14454	-	-	19301	-	17676
ATSP <i>patching</i>	8355	20785	9162	14192	10692	1067	19050	15167	17489
GLSP períodos	-	-	-	-	-	-	212521	-	-
ATSP períodos	-	19493	7960	13161	9462	848	18335	-	15906

Observe na tabela 5.13 que, a abordagem ATSP *patching* gera soluções factíveis para todos os exemplares, dentro do limite de tempo. Além disso, é a única abordagem a gerar solução factível para o mesA. No entanto, nenhuma destas soluções tem garantia de otimalidade, ou seja, a execução computacional é interrompida com o limite de tempo de 1 hora.

Os resultados representados com um traço na tabela 5.13 correspondem a: no caso das abordagens ATSP, soluções infactíveis do ponto de vista do seqüenciamento, ou seja, com sub-rotas; no caso da abordagem GLSP *relax-and-fix* variáveis, soluções infactíveis do ponto de vista prático, ou seja, com atrasos; e, no caso das demais abordagens, não são encontradas soluções inteiras.

Outro experimento com alteração nos tempos de preparação consistiu na geração de uma nova matriz aleatória assimétrica, que obedece a desigualdade triangular. Esta matriz foi obtida gerando-se valores aleatórios uniformemente distribuídos (Uniforme(0,1)) para duas coordenadas, ‘localizando’ os produtos no plano cartesiano, e calculando-se as distâncias euclidianas entre eles. Os valores encontrados foram multiplicados pelo tempo real de uma preparação (1,67 horas). A tabela 5.14 resume os resultados destes experimentos, apresentando os valores de função objetivo para as soluções obtidas.

Observe na tabela 5.14 que, as abordagens GLSP *relax-and-fix* variáveis, GLSP *relax-and-fix* períodos e GLSP períodos (estratégia seqüências independentes) não encontram soluções factíveis para nenhuma das instâncias testadas. A abordagem GLSP encontra solução factível apenas para o exemplar mes4.

Tabela 5.14 Experimentos: tempos de *setup* simétricos, desigualdade triangular válida.

	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
GLSP	-	-	-	-	-	33883	-	-	-
GLSP RF variáveis	-	-	-	-	-	-	-	-	-
GLSP RF períodos	-	-	-	-	-	-	-	-	-
ATSP sub-rotas	16783	27143	17630	21158	21162	19185	27365	23840	26555
ATSP <i>patching</i>	16783	27143	17630	21158	21162	19185	27365	22577	26555
GLSP períodos	-	-	-	-	-	-	-	-	-
ATSP períodos	14186	26992	13995	19834	17579	1830	24958	21002	23572

As melhores abordagens nestes experimentos são as abordagens ATSP, cujas soluções são melhores, sem sub-rotas e sem pedidos pendentes. Note na tabela 5.14 que, a abordagem ATSP sub-rotas não encontra a solução ótima apenas para o exemplar mes6. Ainda em relação a esta abordagem, nos exemplares mes2 e mes4 as soluções encontradas não têm garantia de otimalidade (anexo C). Em relação ao tempo computacional, a abordagem ATSP *patching* é mais rápida com um tempo médio de 417 segundos.

Outros experimentos com variação nos tempos de preparação foram realizados gerando-se valores aleatórios: zero ou 1,67 horas. Primeiramente, foram realizados alguns testes gerando valores uniformemente distribuídos entre zero e um, aproximando o valor gerado para inteiro (0 ou 1) e multiplicando-se por 1,67 horas. Desta forma, os valores gerados têm a mesma probabilidade de ocorrerem, gerando uma matriz menos esparsa que a matriz com valores reais. Como resultado deste experimento, todas as abordagens encontram a solução ótima. Para avaliar o quanto a esparsidade da matriz influencia o desempenho das abordagens, foi gerada uma nova matriz a partir de valores uniformemente distribuídos entre 0,4 e 1. Desta forma, a probabilidade de obter um valor positivo é 83,33%, gerando uma matriz bem menos esparsa.

Conforme esperado, os resultados mostram que a esparsidade na matriz dos tempos de preparação influencia bastante o desempenho das abordagens. Note na tabela 5.15 que, a abordagem GLSP *branch-and-bound* encontra soluções factíveis para todas as instâncias, no entanto, a qualidade das soluções é bastante ruim se comparada com os valores obtidos pelas abordagens ATSP. A abordagem GLSP *relax-and-fix* variáveis é melhor que a

abordagem GLSP *relax-and-fix* períodos, encontrando soluções factíveis para quase todas as instâncias.

	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
GLSP	19323	28912	22459	29192	14652	4457	32847	26281	24164
GLSP RF variáveis	19557	21616	-	12133	12514	8874	28887	15729	21663
GLSP RF períodos	-	29532	41586	-	-	-	-	-	-
ATSP sub-rotas	3869	16772	4799	7484	4011	4085	13661	10140	9095
ATSP <i>patching</i>	3869	16772	4799	7484	4011	4085	13661	10140	8985
GLSP períodos	-	38061	-	-	79202	-	-	-	-
ATSP períodos	3436	16514	4221	7457	3329	4085	13352	9781	8800

As soluções geradas pela abordagem ATSP sub-rotas para os exemplares mesA, mesB, mes4 e mes7 tem garantia de otimalidade. A abordagem com melhor desempenho é abordagem ATSP *patching*, que obtém soluções ótimas em 8 das 9 instâncias testadas com um tempo médio de 1265 segundos.

A matriz de tempos de preparação fornecida pela empresa é bastante esparsa, apenas 171 dos 676 tempos de preparação são positivos (conforme tabela 3 do anexo A), ou seja, 25% do total. No entanto, nos experimentos com dados reais, nem todas as abordagens testadas encontram soluções com garantia de otimalidade para todas as instâncias (conforme apresentado na seção 5.2). Quando geramos valores para a matriz de preparação 0 ou 1,67 horas, a partir de valores uniformemente distribuídos entre 0 e 1, o valor esperado de valores positivos é 338 em 676 valores gerados (50%). No entanto, nos experimentos realizados com esta matriz de preparação todas as abordagens encontram a solução ótima para todas as instâncias.

Em resumo, estes experimentos com diferentes tempos de preparação (st_{ji}) (teste 5) mostram que as alterações na estrutura da matriz de tempos de preparação influenciam o desempenho das abordagens analisadas. As abordagens GLSP são mais suscetíveis às variações nos tempos de preparação, em alguns testes não encontram ao menos uma solução inteira. Em geral, a qualidade soluções obtidas pelas abordagens ATSP são menos afetadas pelas variações dos tempos de preparação, no entanto, o impacto nos tempos computacionais é significativo. Por exemplo, a abordagem ATSP *patching* resolve os exemplares com dados reais em média em 109 segundos, enquanto que, nos experimentos com alterações nos tempos de preparação, o tempo médio é de 1760 segundos.

5.4 Comparação do desempenho das abordagens

Os resultados dos estudos com dados reais, fornecidos pela empresa, juntamente com os resultados dos estudos com alterações nos dados reais, permitem uma comparação mais ampla do desempenho das diferentes abordagens. Foram realizados ao todo mais de 620 experimentos computacionais. A dificuldade para comparar os resultados está em determinar parâmetros de desempenho comum a todas as abordagens. Neste sentido, foram calculados os valores percentuais do número de melhores soluções obtidas. Por exemplo, nos experimentos com dados reais a abordagem GLSP *branch-and-cut* encontrou o melhor valor da função objetivo para 6 dos 9 exemplares testados, assim, a porcentagem de melhores soluções obtidas é 67%. Optamos por escolher a melhor solução obtida porque nem todas as soluções geradas têm garantia de otimalidade. A tabela 5.16 apresenta uma síntese dos resultados obtidos. Por conveniência, os valores para os testes 3 e 5 estão divididos nos índices a, b e c, que correspondem aos seguintes testes realizados:

- Teste 3a – demanda concentrada no período $t=4$;
- Teste 3b – demanda gerada aleatoriamente entre os limites mínimo e máximo da demanda real;
- Teste 3c – demanda gerada aleatoriamente entre 0 e 50 bateladas;
- Teste 5a – matriz de tempos de preparação incluindo tempos de preparação pequenos (0,167horas);
- Teste 5b – matriz de tempos de preparação simétrica com desigualdade triangular válida, gerados aleatoriamente;
- Teste 5c – matriz de tempos de preparação com valores 0 ou 1,67 horas, gerados aleatoriamente.

A tabela 5.16 mostra que as abordagens ATSP *patching* e ATSP períodos encontram os melhores valores de função objetivo em 98% dos experimentos realizados. Vale lembrar que estas abordagens se referem às diferentes estratégias: a abordagem ATSP *patching* resolve os problemas considerando seqüências dependentes, enquanto a abordagem ATSP períodos resolve os problemas considerando seqüências independentes. Observe na tabela 5.16, que a abordagem ATSP com combinação de sub-rotas para a estratégia seqüências dependentes encontra a melhor solução em 77% dos experimentos, ou seja, tem desempenho inferior à mesma abordagem para seqüências independentes (ATSP períodos).

Isto é explicado pelo fato do problema considerando seqüências dependentes ser mais difícil. O método *patching* para a abordagem seqüências independentes não foi implementado.

Tabela 5.16 Porcentagem de melhores soluções em cada experimento.							
SEQ. DEPENDENTES						SEQ. INDEPENDENTES	
	GLSP	GLSP RF variáveis	GLSP RF períodos	ATSP sub-rotas	ATSP <i>patching</i>	GLSP períodos	ATSP períodos
Dados reais	67	67	78	100	100	78	100
Teste 1	10%	0	33	0	100	100	33
	50%	0	0	0	67	100	33
	100%	67	67	33	67	100	33
	200%	67	67	67	100	100	33
	400%	67	67	67	100	100	100
	800%	67	67	67	100	100	67
Teste 2	-10%	33	67	0	100	100	33
	-20%	33	100	33	100	100	67
Teste 3	a	100	67	100	100	100	67
	b	40	40	20	20	100	60
	c	10	20	0	60	90	80
Teste 4	78	-	78	100	100	67	100
Teste 5	a	0	0	0	22	89	0
	b	0	0	0	89	100	0
	c	0	0	0	11	89	0
Média	39	44	34	77	98	47	98

Note na tabela 5.16 que as melhores abordagens GLSP são: a abordagem GLSP *relax-and-fix* variáveis, que encontra, em média, 44% das melhores soluções; e a abordagem GLSP períodos (modelo GLSP seqüências independentes resolvido pelo método *branch-and-cut*), que encontra 47% das melhores soluções, em média.

Conforme discutido no capítulo 4 (seção 4.3), os modelos ATSP consideram que cada família pode ser produzida somente uma vez em cada período. Embora esta seja uma deficiência dos modelos ATSP em relação aos modelos GLSP, nos experimentos realizados com dados reais e com alterações nos dados reais, esta pressuposição parece não interferir do desempenho da abordagem ATSP.

Os experimentos com variação de parâmetros que mais afetam o desempenho das abordagens são os experimentos com alteração nos tempos de preparação (teste 5, na tabela 5.16). Os experimentos com variação nos padrões de demanda, principalmente com valores gerados aleatoriamente, também têm impacto significativo no desempenho das abordagens.

As abordagens GLSP são mais sensíveis à variação de parâmetros do que as abordagens ATSP.

A tabela 5.6 compara o número de vezes que cada abordagem encontrou a melhor solução, os experimentos onde nenhuma das abordagens encontrou solução factível foram desconsiderados na construção desta tabela. Outra forma interessante para comparar as soluções das diferentes abordagens é identificar o número de vezes que as abordagens encontram uma solução factível. A tabela 5.17 apresenta a percentagem de soluções factíveis encontradas por cada experimento (coluna %), e, quando o experimento encontra 100% de soluções factíveis, são apresentados os valores médios da função objetivo (coluna f.o.).

	GLSP		GLSP RF variáveis		GLSP RF períodos		ATSP sub-rotas		ATSP <i>patching</i>		
	%	f.o.	%	f.o.	%	f.o.	%	f.o.	%	f.o.	
Dados reais	100	8384	100	8280	100	8322	100	8219	100	8219	
Teste 1	10%	100	6479	100	6395	100	6542	100	6214	100	6214
	50%	100	7406	100	7278	100	7313	100	6850	100	6840
	100%	100	8259	100	8259	100	8319	100	8001	100	7930
	200%	100	9282	100	9282	100	9282	100	8938	100	8938
	300%	100	10084	100	10084	100	10232	100	9868	100	9868
	800%	100	10622	100	10622	100	11091	100	10577	100	10577
Teste 2	-10%	100	21842	100	21603	100	22171	100	21552	100	21552
	-20%	100	40498	100	40256	100	40467	100	40257	100	40257
Teste 3	a	100	59887	100	59887	100	59887	100	59887	100	59887
	b	100	14044	100	14101	80	-	100	14094	100	14098
	c	70	-	80	-	70	-	80	-	80	-
Teste 4		100	8242	NA	NA	100	8236	100	8178	100	8178
Teste 5	a	33	-	0	-	0	-	44	-	100	12884
	b	11	-	0	-	0	-	89	-	100	22173
	c	100	22476	89	-	22	-	100	8213	100	8213
Média *		88	17890	85	17822	80	18363	95	17678	99	17671

* Média da f.o. dos experimentos: dados reais, teste1, teste2 e teste3a.

A tabela 5.17 se refere aos experimentos considerando a estratégias seqüências dependentes. A tabela 5.18 apresenta os mesmos resultados para a estratégia seqüências independentes.

Podemos observar nas tabelas 5.17 e 5.18 que todas as abordagens encontram soluções factíveis para os seguintes experimentos: dados reais; alteração nos custos de estocagem (teste 1); redução de capacidade (teste 2); demanda concentrada em $t=4$ (teste 3a); e, relaxação da

integralidade das variáveis de dimensionamento de lotes (teste 4). Os resultados dos experimentos com geração de demanda aleatória (teste 3b e 3c) e alteração nos tempos de preparação (teste 5) mostram que estas são as características que mais influenciam o desempenho das abordagens, principalmente as abordagens GLSP. Por exemplo, o GLSP *relax-and-fix* períodos (tabela 5.17) e o GLSP períodos (tabela 5.18) não encontram nenhuma solução factível em nenhum destes experimentos.

		GLSP períodos		ATSP períodos	
		%	f.o.	%	f.o.
Dados reais		100	7609	100	7607
Teste 1	10%	100	5867	100	5314
	50%	100	6562	100	6154
	100%	100	7796	100	7091
	200%	100	8830	100	8452
	300%	100	9351	100	9351
	800%	100	9637	100	9802
Teste 2	-10%	100	19664	100	19422
	-20%	100	38638	100	38146
Teste 3	a	100	59537	100	59514
	b	80	-	100	12835
	c	80	-	80	-
Teste 4		100	7787	100	7561
Teste 5	a	11	-	78	-
	b	0	-	100	18216
	c	22	-	100	7886
Média *		81	17349	97	16699

*Valor médio da f.o. dos experimentos: dados reais, teste1, teste2 e teste3a.

Note na tabela 5.17 que, em média, a abordagem GLSP *branch-and-cut* encontra mais soluções factíveis que as abordagens *relax-and-fix*. No entanto, os valores médios da função objetivo da abordagem GLSP *branch-and-cut* são maiores (considerando experimentos onde as soluções são encontradas por todas as abordagens).

Observe nas tabelas 5.17 e 5.18, que as abordagens ATSP encontram maior porcentagem de soluções factíveis em todos os experimentos. O melhor desempenho foi da abordagem ATSP *patching*, que em 99% dos experimentos encontra soluções factíveis. A abordagem ATSP com proibição de sub-rotas encontra soluções factíveis em 95% dos experimentos considerando a abordagem seqüências dependentes (ATSP sub-rotas) e em 97%

dos experimentos da abordagem seqüências independentes (ATSP períodos).

Em geral, os experimentos com dados aleatórios demandaram mais tempo de processamento computacional. A tabela 5.19 mostra os tempos computacionais médios para os dados reais em todos os testes realizados, bem como uma média geral dos tempos para cada abordagem.

Tabela 5.19 Tempo computacional médio de cada abordagem.								
		SEQ. DEPENDENTES					SEQ. INDEP.	
		GLSP	GLSP RF variáveis	GLSP RF períodos	ATSP sub-rotas	ATSP <i>patch</i> .	GLSP períodos	ATSP per.
Dados reais		1035 / 3600	329 / 3600	619 / 3600	1131	108	1275 / 3600	1167
Teste 1	10%	2598 / 3600	843 / 3600	1332 / 3600	3574	553	2034 / 3600	2393
	50%	661 / 3600	1658 / 3600	792 / 3600	3085	88	2144 / 3600	1133
	100%	1632 / 3600	1044 / 3600	432 / 3600	2457	6	1138 / 3600	244
	200%	152 / 3600	393 / 3600	252 / 3600	1199	9	700 / 3600	195
	400%	940 / 3600	888 / 3600	468 / 3600	854	2	425 / 3600	67
	800%	1382 / 3600	1207 / 3600	340 / 3600	3309	10	297 / 3600	27
Teste 2	-10%	1287 / 3600	333 / 3600	767 / 3600	1104	97	1930 / 3600	23
	-20%	1457 / 3600	1663 / 3600	699 / 3600	1112	2	1284 / 3600	107
Teste 3	a	408 / 3600	185 / 3600	290 / 3600	121	1	1796 / 3600	0
	b	2166 / 3600	1202 / 3600	-	3522	10	-	1419
	c	-	-	-	-	1488	-	-
Teste 4		731 / 3600	NA	846 / 3600	796	15	1337 / 3600	591
Teste 5	a	-	-	-	-	3584	-	-
	b	-	-	-	-	381	-	938
	c	2618 / 3600	-	-	2104	1265	-	135
Média		1313 / 3600	973 / 3600	622 / 3600	1874	476	1305 / 3600	603

Note na tabela 5.19 que os tempos das abordagens GLSP correspondem ao tempo médio que cada abordagem encontra a melhor solução, dentro do tempo limite de uma hora de processamento computacional, ou seja, as soluções não têm garantia de otimalidade. O tempo computacional médio das abordagens ATSP corresponde ao tempo real de execução computacional. Na maioria dos experimentos este tempo não atinge o limite de uma hora.

A figura 2.24 compara os tempos computacionais médios dos experimentos com dados reais, com os tempos computacionais médios de todos os testes realizados. Desta forma, podemos observar que, exceto para a abordagem ATSP períodos, a alteração de parâmetros, implica em aumento nos tempos computacionais.

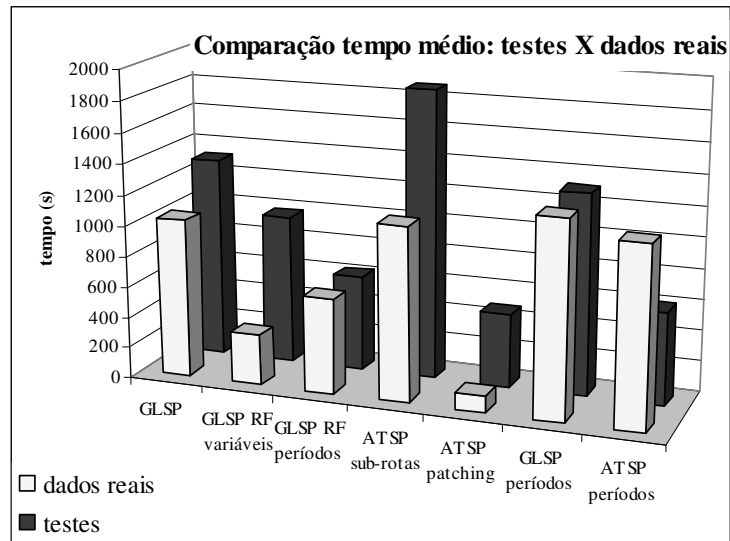


Figura 5.24 Comparação entre tempos médios nos experimentos com dados reais e com dados aleatórios.

Podemos observar na figura 5.24 que as alterações nos dados reais influenciam significativamente o desempenho de tempo computacional da abordagem *ATSP patching*. Mesmo assim, esta abordagem tem o menor tempo computacional em relação às demais, tanto para os experimentos com dados reais quanto para os testes com alteração nos dados fornecidos pela empresa.

6 CONCLUSÕES E PERSPECTIVAS FUTURAS

6.1 Conclusões

Neste trabalho foi estudado o problema integrado de dimensionamento e seqüenciamento de lotes de produção na indústria de suplementos para nutrição animal. Com base em visitas a algumas empresas do setor, podemos caracterizar este problema como: monoestágio; multi-item; com horizonte de planejamento finito; demanda dinâmica, determinística e independente; com restrições de capacidade; com tempos de preparação dependentes da seqüência de produção, para os quais a desigualdade triangular não é válida.

Foram propostas duas abordagens de programação inteira-mista para o problema. A primeira consiste em uma abordagem usando o modelo genérico de dimensionamento e seqüenciamento de lotes (GLSP), que inclui tempos de preparação dependentes da seqüência e custos de horas extras. A segunda consiste em uma reformulação do modelo GLSP usando a formulação do caixeiro viajante assimétrico (ATSP) para representar as decisões de seqüenciamento de lotes, o que resulta em um número menor de variáveis e restrições. Uma diferença significativa na concepção destas abordagens é que na ATSP os produtos somente podem ser produzidos uma vez em cada período. Podem ocorrer situações em que seja mais vantajoso dividir o lote de determinado produto para usá-lo como 'limpante', desta forma, a abordagem ATSP pode não encontrar a solução ótima para o problema.

Cada uma destas abordagens foi desenvolvida para duas diferentes estratégias, relacionadas com a limpeza semanal da linha de produção. Na primeira, os modelos consideram os períodos com seqüências independentes, ou seja, o seqüenciamento é resolvido para cada período t independentemente, mantendo as decisões de dimensionamento integradas. A segunda estratégia considera as seqüências entre os períodos dependentes, ou seja, o seqüenciamento de todos os períodos é resolvido de forma integrada, usando uma variável para conservar o estado de preparação de um período para outro.

Para resolver cada modelo em cada abordagem são propostos métodos de solução específicos. Os modelos GLSP são resolvidos pelo: método exato *branch-and-cut* (usando o *software* AMPL/ CPLEX 9.0), e heurísticas baseadas em programação matemática (heurísticas *relax-and-fix*). Os modelos com seqüenciamento ATSP são resolvidos por meio

de estratégias de eliminação de sub-rotas e uma combinação de eliminação de sub-rotas com a heurística *patching*, ambas usando o *software* AMPL/ CPLEX 9.0.

Nos experimentos com dados reais, as abordagens GLSP fornecem soluções ótimas ou próximas do ótimo, mas em geral sem a garantia de otimalidade, dentro do limite de uma hora de processamento. Mesmo depois de uma hora de processamento, ainda existe uma distância destas soluções em relação ao melhor limitante inferior obtido pelo AMPL/ CPLEX (*gap* de otimalidade), que varia de 3 a 20% nos experimentos realizados. As heurísticas *relax-and-fix* propostas melhoram a solução do problema, mas não apresentam melhoras significativas em relação ao tempo computacional.

As abordagens ATSP aplicadas aos dados reais, foram mais bem sucedidas que as abordagens GLSP, mais rápidas na maior parte dos experimentos realizados, e com a vantagem de em geral provar a otimalidade da solução obtida dentro de uma hora de execução.

Para comparar as estratégias relacionadas à limpeza semanal da linha de produção, foram analisadas as seguintes possibilidades: seqüências independentes com redução da capacidade em cada período; seqüências independentes sem redução da capacidade; e, seqüências dependentes. Os melhores resultados são obtidos pela estratégia seqüências independentes sem redução da capacidade, no entanto, nesta estratégia ainda devem ser incorporados custos extras de preparação. Os resultados destes experimentos mostram que, se a empresa adotar a limpeza semanal dentro do período de produção, o impacto nos custos é significativo, pois a limpeza consome grande parte da capacidade produtiva.

Em todos os experimentos com dados reais, os resultados obtidos pelos modelos e métodos propostos são significativamente melhores que os resultados praticados pela empresa. Isto ocorre principalmente porque a mesma usa a estratégia de acompanhar a demanda período a período, ao invés de antecipar estoques. Experimentos realizados com alterações no *trade-off* de custos fornecidos pela empresa mostram que, para que a solução do modelo coincida com a da empresa, seria necessário que os custos de estocagem fossem muito maiores (mais de 8 vezes). Cabe ressaltar que esta comparação considera apenas o dimensionamento de lotes. Em relação ao seqüenciamento de lotes, somente foram disponibilizados dados para comparação de uma das instâncias, que mostram que o seqüenciamento das abordagens propostas também é mais eficiente.

Para ampliar a análise dos modelos e métodos propostos, foram realizados experimentos com perturbações nos dados fornecidos, bem como, com a geração de dados

aleatórios. Nestes experimentos foram alterados os seguintes parâmetros: custos de estocagem; capacidade; demanda; condição de integralidade das variáveis de dimensionamento de lote; e, matriz de tempos de preparação.

Nos testes com alteração nos custos de estocagem, o objetivo foi analisar melhor o planejamento de produção da empresa (conforme já mencionado) e verificar o desempenho das abordagens. Como esperado, a alteração nos custos de estocagem não influencia significativamente o desempenho das abordagens. A melhor abordagem para a estratégia seqüências dependentes é o modelo ATSP com o método de eliminação e combinação de sub-rotas (ATSP *patching*), enquanto a melhor abordagem para a estratégia seqüências independentes é o modelo ATSP com o método de eliminação de sub-rotas (ATSP períodos).

Nos testes com redução da capacidade observamos que, embora os custos dos programas de produção gerados sejam maiores quando comparados com os dados reais, o *gap* relativo das soluções encontradas é menor. O desempenho das abordagens ATSP é melhor em todas as instâncias testadas.

Em relação aos testes com variação na demanda, o desempenho das abordagens GLSP mostra que esta abordagem é mais sensível à geração de dados aleatórios. Embora a qualidade das soluções ATSP seja menos comprometida do que a abordagem GLSP nestes experimentos, o tempo de execução computacional, principalmente para a abordagem ATSP com método de eliminação de sub-rotas (ATSP sub-rotas), é maior do que nos experimentos com dados reais. As melhores abordagens de solução para as seqüências dependentes e seqüências independentes são: ATSP *patching* e ATSP períodos, respectivamente.

A relaxação na condição de integralidade das variáveis de dimensionamento de lotes (um dos diferenciais dos modelos deste trabalho em relação aos modelos da literatura), não implica em diferenças significativas na qualidade das soluções geradas pelas abordagens testadas. No entanto, os tempos computacionais dos experimentos com as variáveis de lote relaxadas são, em média, 11% menores.

As alterações na matriz de tempos de preparação tiveram grande impacto no desempenho das abordagens testadas, principalmente nas abordagens GLSP. Isto já era esperado, pois, em geral, foram geradas instâncias mais difíceis que o problema com dados reais. Para muitas instâncias, as abordagens GLSP não encontram ao menos soluções factíveis. O desempenho da abordagem ATSP sub-rotas também é significativamente afetado. Para algumas instâncias, também não são encontradas soluções factíveis, dentro do limite de

tempo. Novamente, as abordagens com melhor desempenho são as abordagens ATSP *patching* e ATSP períodos.

Nos experimentos com alteração nos dados fornecidos pela empresa, observamos que a característica de maior impacto no desempenho dos modelos propostos é a estrutura dos tempos de preparação. O problema integrado de dimensionamento e seqüenciamento de lotes de produção na indústria de suplementos possui uma estrutura particular de tempos de preparação que o diferencia dos problemas tratados na literatura.

Considerando todos os estudos computacionais realizados neste trabalho, podemos afirmar que ambos os modelos GLSP e ATSP são adequados para representar o problema de dimensionamento e seqüenciamento de lotes na indústria de suplementos. Embora os modelos ATSP considerem a produção de cada item somente uma vez em cada período, os resultados mostram que isto não compromete a qualidade das soluções obtidas. Quanto aos métodos de solução propostos: para o modelo GLSP seqüências dependentes, o melhor método foi o *relax-and-fix* variáveis; para o modelo ATSP seqüências dependentes, o melhor método foi o método combinação e eliminação de sub-rotas (*patching*). A abordagem que obteve melhor desempenho na resolução do problema com seqüências dependentes foi a abordagem ATSP *patching*. O melhor desempenho para a estratégia seqüências independentes foi obtido pela abordagem ATSP períodos.

Não foram encontrados na literatura trabalhos que tratem especificamente o problema de dimensionamento e seqüenciamento de lotes na indústria de suplementos para nutrição animal. Desta forma, não foi possível comparar diretamente as abordagens propostas com outros estudos. O presente trabalho apresenta contribuições no estudo, definição e análise do problema de dimensionamento e seqüenciamento de lotes na indústria de suplementos para nutrição animal, e, principalmente, no estudo de abordagens efetivas para apoiar as decisões envolvidas neste problema.

6.2 Perspectivas

Nos resultados obtidos nos estudos computacionais, notamos que a estrutura da matriz de tempos de preparação é a característica que mais influencia o desempenho das abordagens GLSP e ATSP propostas neste trabalho. Uma perspectiva de pesquisa futura consiste em aplicar estas abordagens em outros estudos de caso para verificar seus desempenhos. Conforme mencionado no capítulo 2, as outras empresas visitadas possuem

linhas de produção com processos produtivos e processos de planejamento muito semelhantes.

O estudo de caso atual e os possíveis novos estudos de caso podem permitir análises mais detalhadas das formas de resolução do problema na prática. Neste sentido, uma proposta para pesquisa futura é desenvolver heurísticas construtivas e de melhoria para o dimensionamento e para o seqüenciamento de lotes baseadas nas práticas das empresas. O objetivo neste caso é explorar as características específicas do problema para propor métodos de solução mais pragmáticos e comparar com os resultados dos métodos exatos e das heurísticas de programação matemática propostas neste trabalho.

O problema apresentado neste trabalho tem como escopo a indústria de suplementos, que possui características que permitiram tratar o problema como mono-estágio. Algumas unidades produtoras de ração completa possuem uma etapa de conformação da mistura, que devem ser tratadas como dois ou mais estágios (por exemplo, o processo produtivo da UPR, descrito no capítulo 2). Desta forma, uma possibilidade de pesquisa futura é estender os modelos e métodos aqui estudados para tratar este problema.

Neste trabalho optamos por resolver os modelos matemáticos por meio do pacote AMPL/CPLEX, motivados pelos resultados de trabalhos anteriores (Toso; 2003; Toso e Morabito; 2005), e, pela facilidade para implementação computacional. Uma perspectiva de pesquisa futura consiste em utilizar outros métodos como a proposta de solução para o GLSP com tempos de preparação apresentada em Meyr (2000) e comparar os resultados. Outros métodos interessantes para tratar este problema são as metaheurísticas, particularmente os algoritmos evolucionários, como Algoritmos Genéticos e Meméticos.

Alguns estudos recentes apontam para a eficiência de técnicas de solução de problemas inteiro-mistos por meio de heurísticas baseadas em programação matemática, como *Local Branching* e a Busca em Vizinhança Variável (VNS). A idéia básica da heurística *Local Branching* é construir, a partir de uma solução inteira, uma vizinhança que consiste daqueles vetores y , que não diferem de \bar{y} mais do que k coordenadas. Desta forma, restrições de *local branching* são acrescentadas no MIP:

$$\Delta(y, \bar{y}) = \sum_{j | \bar{y}_j = 0} y_j + \sum_{j | \bar{y}_j = 1} (1 - y_j) \leq k$$

Se o MIP resultante é infactível ou não encontra a solução no tempo determinado, a heurística falha; caso contrário, a solução encontrada é a solução da heurística *Local Branching* (Pochet e Wolsey, 2006). Uma perspectiva futura é aplicar esta heurística nos modelos GLSP para melhorar o seqüenciamento dos lotes. A idéia é construir uma

vizinhança para as variáveis y_{jis} , que representam as trocas entre os produtos de um subperíodo para outro. As variáveis y_{jis} podem ser divididas em períodos para explorar vizinhanças de forma diferente em cada período. Cabe mencionar que esta heurística já está incorporada no *solver* CPLEX (10.0).

Os modelos GLSP aplicados ao problema da indústria de nutrição animal, geralmente encontram boas soluções rapidamente, mas sem garantia de otimalidade. Uma perspectiva de pesquisa futura consiste em aplicar uma variação da heurística VNS, a Busca Descendente em Vizinhança Variável, neste problema. Diferente da VNS onde são geradas diversas soluções aleatórias nas vizinhanças de uma solução corrente, a busca descendente consiste na busca local nas diversas estruturas de vizinhança tendo como referência a solução corrente.

As abordagens ATSP foram modeladas e resolvidas neste trabalho por meio de técnicas clássicas como a eliminação de sub-rotas e combinação de sub-rotas. A literatura sobre modelos e métodos para o problema do caixeiro viajante explora diversos aspectos do problema, como por exemplo: métodos mais adequados para problemas assimétricos, algoritmos baseados no *branch-and-bound*, heurísticas de construção de rotas, heurísticas de busca local, etc. Em função dos prazos para conclusão deste trabalho, estas alternativas não foram efetivamente exploradas. Desta forma, uma perspectiva de trabalho futuro é explorar abordagens ATSP alternativas para modelagem e resolução do seqüenciamento de produtos.

Ainda em relação às abordagens ATSP, uma pressuposição dos modelos é a produção de um item somente uma vez no período. Embora os experimentos com dados reais e alterações nestes dados mostrem que os resultados da abordagem ATSP não foram influenciados, consideramos que esta é uma limitação dos modelos. Desta forma, uma proposta futura é estender os modelos ATSP para considerar a possibilidade de um mesmo produto ser produzido mais de uma vez no período. Uma alternativa consiste em estudar o ATSP com *'split delivery'*, onde a demanda de cada produto pode ser dividida dentro do período.

Em casos em que as informações para o planejamento da produção na indústria de suplementos para nutrição animal são muitos suscetíveis às variações do mercado, tanto interno quanto externo, o efeito das incertezas pode ser importante. Além disso, existem questões como a sazonalidade da demanda por produtos e oferta de matérias primas. Nestes casos, uma perspectiva interessante consiste na utilização de programação estocástica e técnicas de otimização robusta, para incorporar nos modelos o tratamento de incertezas das demandas e outros parâmetros.

REFERÊNCIAS BIBLIOGRÁFICAS

ALONSO-AYUSO, A.; ESCUDERO, L. F.; ORTUÑO, M. T.; PIZARRO, C. On a stochastic sequencing and scheduling problem. **Computers & Operations Research**. v. 34 p. 2604 – 2624, 2007.

ALONSO-AYUSO, A.; ESCUDERO, L. F.; PIZARRO, C A.; ROMEIJN, H.E.; MORALES, D. R. On solving the multi-period single-sourcing problem under uncertainty. **Computational Management Science**. v 3; n. 1, p. 29-53, 2006.

ANDRADE, E.L. **Introdução à pesquisa operacional: métodos e técnicas para análise de decisão**. Rio de Janeiro: Livros Técnicos e Científicos Editora, 1989. v.1.

APPLEGATE, D.; BIXBY, R.; CHVATAL, V.; COOK, W. Implementing the DantzigFulkerson -Johnson Algorithm for Large Traveling Salesman Problems. **Mathematical Programming** v. 97 p. 91-153, 2003.

ARAUJO, S. A. **Modelos e Métodos para o Planejamento e Programação da Produção Aplicados ao Setor de Fundições**. 2003. Tese (Doutorado em Ciências da Computação e Matemática Computacional), ICMC Universidade Estadual de São Paulo, São Carlos.

ARAUJO, S. A.; ARENALES, M. N. Problema de Dimensionamento de Lotes Monoestágio com Restrição de capacidade: modelagem, método de resolução e resultados computacionais. **Pesquisa Operacional**, v. 20, n. 2, p. 287-306, 2000.

ARAÚJO, S. A.; ARENALES, M. N.; CLARK, A. R. Joint rolling-horizon scheduling of materials processing and lot-sizing with sequence-dependent setups. **Journal of Heuristics**. v. 13, p. 337–358, 2007.

ARENALES, M. N.; ARMENTANO, V. A.; MORABITO, R.; YANASSE, H. H. **Pesquisa Operacional**. 1. ed. Rio de Janeiro: Campus / Elsevier, 2007. v. 1. 523 p.

ARMENTANO, V. A.; FRANÇA, P. M.; TOLEDO, F. .M. B. A network flow model for the capacitated lot-sizing problem. *Omega International Journal of Management Science*. v. 27, n.2, p. 275-284, 1999.

ASKIN, R. e STANDRIDGE, C. **Modeling and analysis of manufacturing systems**. New York: John Wiley & Sons, 1993.

ATAMTÜRK, A.; SAVELSBERGH, M. W. P. Integer-Programming Software Systems. **Annals os Operations Research**. v.140, p. 67-124, 2005.

BERALDI, P.; GHIANI, G.; GRIECO, A.; GUERRIERO, E. Fix and Relax Heuristic for a Stochastic Lot-Sizing Problem. **Computational Optimization and Applications**. v. 33, p. 303–318, 2006.

BERALDI, P.; GHIANI, G.; GRIECO, A.; GUERRIERO, E. Rolling-horizon and fix-and-relax heuristics for the parallel machine lot-sizing and scheduling problem with sequence-dependent set-up costs. **Computers & Operations Research**. doi:10.1016/j.cor.2007.04.003.

BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v.22, n.2, p.241-264, 2002.

BILLINGTON, P. J.; McCLAIN, J. O.; MAES, J.; MILLEN, R.; VAN WASSENHOVE, L. N. Multi-item lot-sizing in capacitated multi-stage serial systems. **IIE Transportation**. v. 26, p. 12-18, 1994.

BILLINGTON, P. J.; McCLAIN, J. O.; THOMAS, L. J. Mathematical programming approaches to capacity MRP systems: review formulation and problem reduction. **Management Science**. v. 19, p. 1126-1141, 1983.

BITRAN G.R. e YANASSE H.H., Computational Complexity of the Lot Size Problem. **Management Science**. v. 28, n. 10, p. 1174-1186, 1982.

BIXBY, R. E. Solving Real-World Linear Programs: A Decade and more of Progress. **Operations Research**. v. 50, n. 1, p. 3-15, 2002.

BRAHIMI, N.; DAUZEREPERES, S.; NAJID, N.M.; NORDLI, A. Single item lot sizing problems. **European Journal of Operational Research**. v. 168, p. 1-16, 2006.

BRITO, A. B., STRINGHINI, J.H. **Aprendendo Nutrição Animal Online**. Disponível em: <<http://nutrimail.vila.bol.com.br>>. Acesso em: 23/07/2006.

BURBIDGE, J. L. **The Principles of Production Control**. Plymouth: Mac Donald and Evans Limited, 1978.

BURIOL, L.; FRANCA, P. M.; MOSCATO, P. A new memetic algorithm for the asymmetric traveling salesman problem. **Journal of Heuristics**. v. 10, n. 5, p. 483-506, 2005.

CARPANETO, G.; DELL'AMICO, M.; TOTH, P. Exact solution of large scale asymmetric travelling salesman problems, **ACM Transactions on Mathematical Software**. v. 21, n. 4, p. 394-409, 1995.

CHAPPEL, A.E. Linear Programming Cuts Costs in Production of Animal Feeds. **Operations Research Quarterly**. v.35, n.1, p.19-26, mar. 1974.

CHEN, K.; JI, P. A mixed integer programming model for advanced planning and scheduling (APS). **European Journal of Operational Research**. v. 181, p. 515-522, 2007.

CIRASELLA, J.; JOHNSON, D. S.; MCGEOCH, L. A.; ZHANG, W. The asymmetric traveling salesman problem: Algorithms, instance generators, and tests, **Springer Lecture Notes in Computer Science**. v. 2153, p. 32-59, 2001.

CLARK, A. R. A Local Search Approach to Lot Sizing and Sequencing. In: TUCCI, M.; GARETTI, M. 2000. Florença - Itália. **Proceedings of the Third International Workshop of the IFIP WG5.7 Special Interest Group on Advanced Techniques in Production Planning & Control**. Florença, Firenze University, 2000.

CLARK, A. R.; CLARK, S. J. Rolling-horizon lot-sizing when set-up times are sequence-dependent. **International Journal of Production Research**. v. 38, p. 2287-2307, 2000.

CLARK, A.R. Optimization Approximations for Capacity Constrained Material Requirement Planning. **International Journal of Production Economics**. v. 84, p. 115-131, 2003.

CLARK, A.R., ARMENTANO, V.A. The application of valid inequalities to the multi-stage lot sizing problem. **Computers & Operations. Research**. v. 22, n.7, p. 669-680, 1995.

CUTAIT, M. S. **Palavra do Presidente**. Disponível em: <<http://www.sindiracoes.org.br/institucional/palavra/>>. Acesso em: 06/01/2008.

DANNA, E.; ROTHBERG, E.; LE PAPE, C. Exploring relaxation induced neighborhoods to improve MIP solutions. **Mathematical Programming**. v. 102, p. 71-90, 2005.

DE BODT, M. A.; GELDERS, L. F.; VAN WASSENHOVE, L. V. Lot sizing under dynamic demand conditions: a review. **Engineering Costs and Production Economics**. v.8, p. 165-187, 1984.

DREXL, A., HAASE, K. Proportional Lotsizing and Scheduling. **International Journal of Production Economics**. v. 40, p.73-87, 1995.

DREXL, A., KIMMS, A. Lot sizing and Scheduling – Survey and extensions. **European Journal of Operational Research**. v. 99, p. 221-235, 1997.

ELMAGHRABY, S. The economic lot scheduling problem (ELSP): Review and extensions. **Management Science**. v. 24, p. 587-98, 1978.

ELMAGHRABY, S.E. The economic lot scheduling problem (ELSP): review and extensions, **Management Science** v. 24, p. 587-598, 1978.

ERLENKOTTER, D., Ford Whitman Harris and the economic order quantity model. **Operations Research**. v. 38, p. 937- 946, 1990.

FERREIRA, D. **Abordagens para o Problema Integrado de Dimensionamento e Sequenciamento de Lotes da Produção de Bebidas**. 2006. Tese (Doutorado em Engenharia de Produção) Departamento de Engenharia de Produção, Universidade Federal de São Carlos, São Carlos.

FERREIRA, D.; MORABITO, R.; RANGEL, S. Um modelo de otimização inteira mista e heurísticas *relax and fix* para a programação da produção de fábricas de refrigerantes de pequeno porte. Aceito para publicação, **Produção**, 2008.

FINEP (Financiadora de Estudos e Projetos) (2004). **Relatório Setorial Final – Setor: Insumos Suínos**. Autor: Giuliana Santini. Disponível em: <http://www.finep.gov.br/PortalDPP/relatorio_setorial_final/relatorio_setorial_final_insumos_suinos>. Acesso em:16/10/2006.

FISCHETTI, M.; LODI, A. Local branching. **Mathematical Programming**. v. 98, p. 23-47, 2003.

FISCHETTI, M.; LODI, A. Repairing MIP infeasibility through local branching. **Computers & Operations Research**. Digital Object Identifier (DOI) 10.1016/j.cor.2006.08.004, 2006.

FLEISCHMANN, B. The discrete lot-sizing and scheduling problem with sequence-dependent setup-costs. **European Journal of Operational Research**. v. 75, p. 395-404, 1994.

FLEISCHMANN, B.; MEYR, H.. The general lot sizing and scheduling problem. **OR Spectrum**. v. 19, n. 1, p. 11-21, 1997.

FLORIAN, M.; LENSTRA, J. K.; RINNOY KAN, A. H. G. Deterministic production planning and complexity. **Management Science**. v. 26, p. 669-679, 1980.

FLORIAN, M.; LENSTRA, J.K.; RINNOY KAN, A.H.G. Deterministic Production Planning Algorithms and Complexity. **Management Science**. v. 26, n. 7, p. 669-679, 1980.

FOURER, R.; GAY, D. M.; KERNIGHAN, B. W. (2003). **AMPL - A Modeling Language for Mathematical Programming**. 2 ed. Duxbury Press / Brooks-Cole Publishing Company, 2003. 517 p.

FRANÇA, P. M.; ARMENTANO, V. A.; BERRETTA, R. E.; CLARK, A. R. A heuristic method for lot-sizing in multi-stage systems. **Computers & Operations Research**. v. 24, n. 9, p. 61-874, 1997.

FRIEZE, A. M.; DYER, M. E. On a patching algorithm for the random asymmetric travelling salesman problem. **Mathematical Programming**. v. 46, p. 361-378, 1990.

FRIEZE, A. M.; KARP, R. M.; REED, B. When is the assignment bound tight for the asymmetric traveling-salesman problem? **SIAM Journal on Computing**. v. 24, n. 3, p. 484-493, 1995.

GELDERS L F., VAN WASSENHOVE L. N. Production planning: a review. **European Journal of Operational Research**. v. 7, p. 101-110, 1981.

GERSHWIN, S. **Manufacturing systems engineering**. New Jersey: Prentice Hall, 1994.

GLOVER, F.; GUTIN, G.; YEO, A.; ZVEROVICH, A. Construction heuristics for the asymmetric TSP. **European Journal of Operational Research**. v. 129, p. 555-568, 2001.

GLOVER, F.; GUTIN, G.; YEO, A.; ZVEROVICH, A. Construction heuristics for the asymmetric TSP. **European Journal of Operational Research**, 2000.

GLOVER, F.; LAGUNA, M. **Tabu Search**. Kluwer Academic. 382p.

GODINHO FILHO, M.; FERNANDES, F. C. F.. Paradigmas Estratégicos de Gestão da Manufatura (PEGEMs): Elementos-Chave e Modelo Conceitual. **Rev. Gestão e Produção**. São Carlos, v. 12, n. 3, 2005.

GRAVES, S.C.; RINNOOY KAN, A.H.G.; ZIPKIN, P.H. Logistics of Production and Inventory. **Handbook in operations research and management science**. v. 4. Amsterdam: North-Holland, 1993.

GÜNTER, H. O. Planning lot sizes and capacity requirements in a single stage production system. **European Journal of Operational Research**. v. 31, p.223-231, 1987.

GUPTA, D.; MAGNUSSON, T. The capacitated lot-sizing and scheduling problem with sequence dependent setup costs and setup times. **Computers & Operations Research**. v. 32, p. 727-747, 2005.

GUPTA, Y.P.; KEUNG, Y. A review of multi-stage lot-sizing models. **International Journal of Operations and Production Management**. v. 10, n. 9, p. 57-73, 1990.

GUTIN, G.; YEO, A.; ZVEROVITCH, A. Exponential Neighborhoods and Domination Analysis for the TSP. In **The Traveling Salesman Problem and its Variations** (G. Gutin and A. Punnen, eds.), Kluwer, Dordrecht, 2002.

HANSEN, P.; MLADENOVIC, N. Variable Neighborhood search: principles and applications. **European Journal of Operational Research**. v. 130, p. 449-467, 2001.

HANSEN, P.; MLADENOVIC, N.; UROSEVIC, D. Variable neighborhood search and local branching. **Computers & Operations Research**. v. 33, p. 3034-3045, 2006.

HAX, A.; CANDEA, D. **Production and inventory management**. Englewood Cliffs: Prentice-Hall, 1984.

HILLIER, F. S.; LIERBERMAN, G. **Introdução à Pesquisa Operacional**. 8. ed. Rio de Janeiro: Mcgraw-hill, 2006. 852p.

HINDI, K. S. Solving the single-item, capacitated dynamic lot sizing problem with startup and reservation costs by tabu search. **Computers and Industrial Engineering**. v. 24, n. 4, p. 701-707, 1995.

i2 **Trade Matrix**. Disponível em: <http://www.i2.com>. Acesso em: 15/08/ 2002.

- IFIF (Internacional Feed Industry Federation). **A Global Perspective on the Animal Feed Industry**. Disponível em: <http://www.ifif.org/files/WorldFeedOverview.ppt>. Acesso em: 21/07/2006.

- IFIF (Internacional Feed Industry Federation). **Global Feed**. Disponível em: http://www.ifif.org/global_stats1.php. Acesso em: 27/07/2007.

ILOG **CPLEX 9.1 User's Manual**, ILOG S.A. Disponível em: <http://www.ampl.com/BOOKLETS/amplcplex91userguide.pdf>. Acesso em: 09/09/2004.

JANS, R.; DEGRAEVE, Z. Meta-heuristics for dynamic lot sizing: a review and comparison of solution approaches. **European Journal of Operational Research**. v. 177, n. 3, p. 1855-1875.

JOHNSON, D. S., GUTIN, G., MCGEOCH, L. A., YEO, A., ZHANG, W. AND ZVEROVICH, A. Experimental analysis of heuristics for the asymmetric travelling salesman problem - algorithms, instance generators and tests In: GUTIN, G.; PUNNEN, A. P. **The Traveling Salesman Problem and its Variations**. Kluwer, 2002.

JONHSON, L. A.; MONTGOMERY, D. C. **Operations research in production planning, scheduling and inventory control**. New York: John Wiley & Sons, 1974.

JUNGER, M.; REINELT, G.; RINALDI, G. The traveling salesman problem. In: BALL, M. O.; MAGNANTI, T. L.; MONMA, C. L.; NEMHAUSER, G. L **Network Models**. . North Holland, 1995. p. 225–330. (Handbooks in Operations Research and Management Science).

KARIMI, B.; GHOMI, S. M. T. F.; WILSON, J. M. The capacitated lot sizing problem: a review of models and algorithms. **Omega International Journal of Management Science**. v. 31, n. 5, p. 365-378, 2003.

KARP, R. M. A patching algorithm for the nonsymmetric traveling-salesman problem. **SIAM Journal on Computing**. v. 8, n. 4, p. 561–573, 1979.

KARP, R. M. AND STEELE, J. M. Probabilistic analysis of heuristics. In LAWLER, E. L.; LENSTRA, J. K.; RINNOY KAN, A. H. G.; SHMOYS, D. B. **The Traveling Salesman Problem - A Guided Tour of Combinatorial Optimization**. Chichester: Wiley, 1985.

KIRCA, O.; KÖKTEN, M. A new heuristic approach for the multi-item dynamic lot sizing problem. **European Journal of Operations Research**. v. 75, p. 332-341, 1994.

KISTNER, K. P.; SWITALSKI, M. Hierarchical production planning necessity, problems, and methods. **Mathematical Methods of Operations Research**. v. 33, n.3, p. 199-212, 1989.

LAGUNA, M. A Heuristic for Production Scheduling and Inventory Control in the presence of Sequence-Dependent Setup Times. **Internal Research Report**. University of Colorado, 1999.

LAPORTE, G. The traveling salesman problem: An overview of exact and approximate algorithms. **European Journal of Operational Research**. v. 59, p. 231–247, 1992.

LAPORTE, G.; NOBERT, Y. A Cutting Planes Algorithm for the m-Salesmen Problem. **The Journal of the Operational Research Society**, v. 31, n. 11, p. 1017-1023, 1980.

LAWLER, E. L.; LENSTRA, J. K.; RINNOY KAN, A. H. G.; SHMOYS, D.B. **The Traveling Salesman Problem - A Guided Tour of Combinatorial Optimization**, Chichester: Wiley, 1985.

LUCHE, J. R.; MORABITO, R.. Otimização na programação da produção de grãos eletrofundidos: Um estudo de caso. **Gestão & Produção**. v. 12, n.1, p. 135-149, 2005.

LUCHE, J.R.; MORABITO, R.; PUREZA, V. Combinig process selection and lot sizing models for the production scheduling of electrofused grains. **Asia-Pacific Journal of Operations Research, aceito para publicação**, 2007.

MAES J.; VAN WASSENHOVE, L. N. Multi-Item Single-Level Capacitated Dynamic Lot-Sizing Heuristics: A General Review. **Journal of Operational Research Society**, v. 39, n. 11, p. 991-1004, 1988.

MAES, J.; McCLAIN, J.O.; VAN WASSENHOVE, L. N. Multilevel capacitated lotsizing complexity and LP-based heuristics. **European Journal of Operational Research**. v. 53, p.131-148, 1991.

MAES, J.; VAN WASSENHOVE, L. Multi item single level capacitated dynamic lotsizing heuristics: a computational comparison (part I and II). **IIE Transactions**. v. 18, 114–129, 1986.

MENDES, A.B. **Programação de frota de apoio a operações “offshore” sujeita a requisições de múltiplas embarcações simultâneas**. Set. 2006. Texto Qualificação (Doutorado em Engenharia Naval e Oceânica) Escola Politécnica, Universidade de São Paulo, São Paulo.

MENDES, A.C. **Análise do processo de extrusão na indústria de "PET-FOOD" para a aplicação de técnicas de controle avançado**. Fev. 2003. 366p. Dissertação (Mestrado em Engenharia de Alimentos) Faculdade de Engenharia de Alimentos, Universidade Estadual de Campinas, Campinas.

MEYR, H. Simultaneous lotsizing and scheduling by combining local search whit dual reoptimization. **European Journal of Operational Research**. v.120, n. 2, p. 311-326, 2000.

MEYR, H. Simultaneous lotsizing and scheduling on parallel machines. **European Journal of Operational Research**. v. 139, n.2, p. 277-292, 2002.

MICHALEWICZ, Z. FOGEL, D. B. **How to solve it: Modern Heuristics**. 3 ed. Berlim, Sringer-Verlag, 2002. 551p.

MLADENOVIC, N. HANSEN, P. Variable Neighborhood search. **Computers & Operations Research**. v. 24, n. 11, p. 1097-1100, 1997.

NAHMIAS, S. **Production and operations analysis**. Hoewood: Irwin, 1995.

ORMAN, A. J. AND WILLIAMS, H. P. **A survey of different integer programming formulations of the traveling salesman problem**. Working paper LSEOR 04.67, London School of Economics, Dept of Operational Research, LSE, Houghton Street, London, WC2 2AE, UK, 2004.

ÖZDAMAR, L. BARBARASOGLU, G. Hybrid heuristics for the multi-stage capacitated lot sizing and loading problem. **Journal of the Operational Research Society**. v. 50, n. 8, p. 810-825, 1999.

PADBERG, M.; RINALDI, G. A Branch and Cut Algorithm for the Resolution of Large-scale Symmetric Traveling Salesman Problems. **SIAM Review**, v. 33, n.1, p. 66-100, 1991.

PATAKI, G. Teaching Integer Programming Formulations Using the Traveling Salesman Problem. **SIAM review**, v. 45, p. 116-123, 2003.

PEKNY, J.F.; MILLER, D.L. A parallel Branch and Bound Algorithm for Solving Large Asymmetric Travelling Salesman Problems. **Proceedings ACM**, p. 56-62, 1990.

PEREIRA, A.; CARVALHO, F.; PEDROSO, J.; CONSTANTINO, F. Iterated Local Search and Tabu Search for a Discrete Lot Sizing and Scheduling Problem. **Kluwer Academic Publishers**, 2002.

POCHET, Y.; WOLSEY, L. A. **Production Planning by Mixed Integer Programming**. New York: Springer Verlag, 2006. (Series in Operations Research and Financial Engineering).

PONAMBALAM, S. G.; REDDY, M. M. A GA-SA Multiobjective Hybrid Search Algorithm for Integrating Lot Sizing and Sequencing in Flow-Line Scheduling. **International Journal of Advanced Manufacturing Technology**. v. 21, p. 126-137, 2003.

PUREZA, V. M. M. **Tópicos em métodos heurísticos**. Notas de aula da disciplina: Tópicos Avançados em Gerência da Produção Industrial. Universidade Federal de São Carlos, 2005.

REEVES, C. R. Genetic Algorithms for the Operations Researcher. **INFORMS Journal of Computing**. v. 9, n. 3, p. 231-250, 1997.

ROCHA, M. P.; RAVETTI, M. G.; MATEUS, G. R.; PARDALOS, P. M. Solving parallel machines scheduling problems with sequence-dependent setup times using variable neighbourhood search. **IMA Journal of Management Mathematics**, v.18, p. 101-115, 2007.

SALOMON M.; KROON L.G.; KUIK L.; VAN WASSENHOVE L.N. Some extensions of discrete lot sizing and scheduling problem. **Management Science**. v. 37, n. 7, p. 801-812, 1991.

SALOMON, M.; SOLOMON, M.; WASSENHOVE, L.; DUMAS, Y. Solving the discrete lot sizing and scheduling problem with sequence dependent set-up costs and set-up times using the Travelling Salesman Problem with time windows. **European Journal of Operational Research**. v. 100, p. 494-513, 1997.

SAP- APO, 2002. Advanced Production Optimiser. Disponível em: <http://www.sap.com/apo/>. Acesso em: 15/08/2002.

SCHMIDT, A. **Peletização na Alimentação Animal**. Disponível em: http://www.suino.com.br/nutricao/noticia.asp?pf_id=24666&dept_id=6. Acesso em: 20/10/2006.

SHAPIRO. J.F. Mathematical Programming Models and Methods for Production Planning and Scheduling. In: Graves, S. C., et al. **Handbooks in Operational Research and Management Science**. ed. Elsevier, 1993. p. 371-443.

SIKORA, R. A Genetic Algorithm for Integrating Lot-Sizing and Sequencing in Scheduling a Capacitated Glow Line. **Computers Industrial Engineering**. v. 30, n. 4, p. 969-981, 1996.

SINDIRAÇÕES (SINDICATO NACIONAL DA INDÚSTRIA DE ALIMENTAÇÃO ANIMAL) **Posicionamento da Indústria de Alimentação Animal**. Disponível em: < <http://www.sindiracoes.org.br>>. Acesso em: 07/02/2007.

STAGGEMEIER, A.T.; CLARK, A.R.; AICKELIN, U.; SMITH, J. A Hybrid Genetic Algorithm to solve a Lot Sizing and Scheduling Problem. **16th Triennial Conference of the International Federation of Operational Societies**. Edinburgh, Escócia, 2002.

STAGGEMEIER, A.T., CLARK, A.R. A survey of lot-sizing and scheduling models. In: XXXIII SBPO-Simpósio Brasileiro de Pesquisa Operacional, 2001, Campos do Jordão. Anais, 2001.

TOLEDO, C. F. M. ; FRANÇA, P.M. ; MORABITO, R. ; KIMMS, A. Multi-Population Genetic Algorithm to Solve the Synchronized and Integrated Two-Level Lot Sizing and Scheduling Problem. **International Journal of Production Research**, 2007.

TOLEDO, C. F. M. ; FRANÇA, P.M.; MORABITO, R. ; KIMMS, A. Um Modelo de Otimização para o Problema Integrado de Dimensionamento de Lotes e Programação da Produção em Fábricas de Refrigerantes. **Pesquisa Operacional**, 2007. (aceito para publicação).

TOLEDO, F.M.B. **Dimensionamento de lotes em máquinas paralelas**. 1998. Tese (Doutorado em Engenharia Elétrica) Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, Campinas.

TOLEDO, F.M.B.; SHIGUEMOTO, A.L. Lot-Sizing Problem with Several Production Centers **Pesquisa Operacional**. v.25, n.3, p.479-492, 2005.

TOSO, E.A.V, MORABITO, R. Otimização no dimensionamento e seqüenciamento de lotes de produção: estudo de caso numa fábrica de rações. **Gestão & Produção**. São Carlos, v.12, n.2, 203-217, 2005.

TOSO, E.A.V., **Otimização do problema integrado de dimensionamento de lotes e programação da produção**: Estudo de caso na indústria de rações. 2003. 133p. Dissertação (Mestrado em Engenharia de Produção) Departamento de Engenharia de Produção, Universidade Federal de São Carlos, São Carlos.

TRIGEIRO, W.W. A simple heuristic for lot sizing with setup times. **Decision Sciences**. v. 20, n. 3, p. 294–303, 1989.

TRIGEIRO, W.W.; THOMAS, L.J.; McCLAIN, J.O. Capacitated lot sizing with setup times. **Management Science**, v. 35, p. 353-366, 1989.

VOLLMANN, T. E.; BERRY, W .L.; WHYBARK, C. **Manufacturing planning and control systems**. 4. ed. New York, USA: Irwin, 1997.

VÖRÖS, J. On the relaxation of multi-level dynamic lot-sizing models. **International Journal of Production Economics**. v. 77, pp. 53-61, 2002.

WAGNER, B., DAVIS, D.J. A search heuristic for the sequence-dependent economic lot scheduling problem. **European Journal of Operational Research**. v. 141. p. 133-146, 2002.

WAGNER, H.M.; WHITIN, T.M., Dynamic version of the economic lot size model, **Management Science** v. 5, p. 89-96, 1958.

WILLIAMS, P. **Model Building in Mathematical Programming**. New York: John Wiley & Sons, 1993.

WINSTON, W. **Operations Research: Applications and algorithms**. Boston: PWS-Kent, 1991.

WOLSEY, L. A. **Integer Programming**. New York: Wiley, 1998. 264p. (Series in Mathematics and Optimization).

XIE, J.; DONG, J. Heuristic Genetic Algorithms for General Capacitated Lot-Sizing Problems. **Computers and Mathematics with Applications**. v. 44, p. 263-276, 2002.

ZHANG, W. A note on the complexity of the asymmetric travelling salesman problem. **Operations Research Letters**. v. 20, p. 31-38, 1997.

ZHANG, W. Truncated Branch-and-Bound: A Case Study on the Asymmetric TSP. **Spring Symposium on AI and NP-Hard Problems**. p. 160-166, 1993.

APÊNDICE A – PLANO DE AGREGAÇÃO DOS PRODUTOS EM FAMÍLIAS

A UPS produz cerca de 200 produtos, sendo necessário agregar os produtos em famílias para tornar o modelo mais tratável computacionalmente.

Inicialmente tentamos utilizar o conceito de famílias comerciais da empresa, como por exemplo: premix suínos, premix frango, núcleos bovinos. Entretanto dentro destas famílias existem produtos que pertencem a grupos de contaminação diferentes, ou seja, não podem ser produzidos um depois do outro sem que ocorra uma limpeza na linha de produção, além de não terem as mesmas relações de precedência.

Existe um total de 51 grupos de contaminação definidos pelo departamento técnico. Dentro dos grupos de contaminação, observamos que existem produtos de diferentes famílias comerciais, e ainda que existem grupos que possuem as mesmas relações de precedência. Por exemplo: os grupos 0, 5, 10, 17 e 20, têm o mesmo conjunto de produtos antes dos quais não devem ser produzidos e também o mesmo conjunto de produtos depois dos quais não devem ser produzidos.

Portanto, para serem agregados dentro de uma mesma família os produtos devem atender aos seguintes critérios:

- a) pertencer ao mesmo grupo de contaminação ou a grupos que tenham as mesmas relações de precedência;
- b) em cada grupo só podem existir produtos do mesmo tipo (núcleos, premixes, minerais, etc.), pois os tempos de processamento variam de acordo com o tipo de produto.

A tabela A1, fornecida pela empresa, apresenta as relações de precedência entre os grupos de contaminação. A tabela A2 mostra a agregação em famílias desenvolvida neste trabalho a partir dos grupos de contaminação.

Tabela A2. Agregação em famílias.	
família	grupos de contaminação
fam1	0, 5, 10, 17 e 20
fam2	15, 25, 30 e 51
fam3	50, 60, 65 e 67
fam4	35 e cód.226224*
fam5	52
fam6	66
fam7	90, 100 e 107
fam8	Nh Fos 90, 100 e 107
fam9	cód.130620 do grupo 105**
fam10	núcleos SD 105
fam11	cód.130720 do grupo 105**
fam12	105
fam13	núcleos 105
fam14	91
fam15	92 e 95
fam16	115, 120, 126 e 130
fam17	135, 140, 145 e 150
fam18	premix 135, 140, 145 e 150
fam19	155
fam20	160
fam21	165
fam22	AG 165
fam23	999
fam24	777
fam25	666
fam26	166

* O produto correspondente ao código 226224 do grupo 52 é um premix, o restante dos produtos deste grupo são núcleos, como estes 'tipos' de produtos têm tempos de processamento diferentes não podem ser agregados na mesma família.

** Os produtos correspondentes aos códigos 130620 e 130720 têm demandas muito altas. Na versão do GAMS disponível no laboratório de pesquisa em que foi desenvolvido este trabalho, só permite variáveis inteiras de 0 a 100, portanto foi necessário separá-los em famílias diferentes.

Como os tempos de preparação entre os produtos da mesma família são de segunda ordem, menos de 10 minutos, foram desprezados. Sendo assim, a desagregação das famílias é simples.

ANEXO A – PARÂMETROS PARA EXEMPLOS REAIS

Cabe ressaltar que, para proteger as informações fornecidas pela empresa, todos os dados foram distorcidos, mantendo-se apenas a proporcionalidade dos mesmos.

Tabela A1. Consumo de capacidade por produto i (p_i), custos* de manter uma unidade em estoque (h_i).		
i	p_i	h_i
<i>fam1</i>	0,4	660
<i>fam2</i>	0,4	170
<i>fam3</i>	0,4	85,1
<i>fam4</i>	0,4	151,2
<i>fam5</i>	0,2	103,4
<i>fam6</i>	0,4	110
<i>fam7</i>	0,2	42,1
<i>fam8</i>	0,2	44,3
<i>fam9</i>	0,2	39,2
<i>fam10</i>	0,2	48,8
<i>fam11</i>	0,2	77,5
<i>fam12</i>	0,2	59,1
<i>fam13</i>	0,3	84,9
<i>fam14</i>	0,3	92,2
<i>fam15</i>	0,2	31,2
<i>fam16</i>	0,2	43,2
<i>fam17</i>	0,2	62,1
<i>fam18</i>	0,4	59,2
<i>fam19</i>	0,6	137,1
<i>fam20</i>	0,6	102,6
<i>fam21</i>	0,3	44,6
<i>fam22</i>	0,2	44,3
<i>fam23</i>	0,2	50,1
<i>fam24</i>	0,2	52,5
<i>fam25</i>	0,3	98,6
<i>fam26</i>	0,2	69,2

* em unidades monetárias (u.m.)

Tabela A2. Capacidade disponível (horas) por período (k_t), limite máximo de hora extra permitido por período (u_t) e custos* de hora extra por período (co_t).

t	k_t	u_t	co_t
1	64	16	859,2
2	64	16	859,2
3	64	16	859,2
4	64	16	859,2

* em unidades monetárias (u.m.)

Tabela A3. Matriz dos tempos de preparação (st_{jis}).

	fam1	fam2	fam3	fam4	fam5	fam6	fam7	fam8	fam9	fam10	fam11	fam12	fam13
fam1	0	0	1,67	1,67	1,67	0	1,67	1,67	1,67	1,67	0	1,67	0
fam2	1,67	0	1,67	1,67	1,67	0	1,67	1,67	1,67	1,67	1,67	1,67	1,67
fam3	0	0	0	0	0	0	1,67	1,67	1,67	1,67	0	1,67	0
fam4	0	0	0	0	0	0	1,67	1,67	1,67	1,67	0	1,67	0
fam5	0	0	0	0	0	0	1,67	1,67	1,67	1,67	0	1,67	0
fam6	1,67	0	0	1,67	1,67	0	1,67	1,67	1,67	1,67	1,67	1,67	1,67
fam7	0	0	0	0	0	0	0	0	0	0	0	0	0
fam8	0	0	0	0	0	0	0	0	0	0	0	0	0
fam9	0	0	0	0	0	0	0	0	0	0	0	0	0
fam10	0	0	0	0	0	0	0	0	0	0	0	0	0
fam11	1,67	0	0	1,67	1,67	0	0	0	0	0	0	1,67	1,67
fam12	0	0	0	0	0	0	0	0	0	0	0	0	0
fam13	0	0	0	0	0	0	0	0	0	0	0	0	0
fam14	0	0	0	0	0	1,67	1,67	1,67	1,67	0	0	1,67	0
fam15	0	0	0	0	0	0	0	0	0	0	0	0	0
fam16	0	0	0	0	0	0	0	0	0	0	0	0	0
fam17	0	0	0	0	0	0	0	0	0	0	0	0	0
fam18	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67
fam19	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67
fam20	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67	1,67
fam21	1,67	0	0	1,67	0	0	0	0	0	0	0	1,67	1,67
fam22	0	0	0	0	0	0	0	0	0	0	0	0	0
fam23	0	0	0	0	0	0	0	0	0	0	0	0	0
fam24	0	0	0	0	0	0	0	0	0	0	0	0	0
fam25	0	0	0	0	0	1,67	1,67	1,67	1,67	0	0	1,67	0
fam26	0	0	0	0	0	0	0	0	0	0	0	0	0

Tabela A3 (continuação).

fam22	15	19	11	11	13	18	21	22	2	3	2	2
fam23	1	2	1	2	2	2	2	1	1	2	3	1
fam24	38	54	34	28	53	68	77	9	22	13	25	20
fam25	1	1	1	3	0	0	0	2	1	2	3	1
fam26	19	18	14	18	19	17	27	22	24	21	15	36
produto	mes5				mes6				mes7			
	t = 1	t = 2	t = 3	t = 4	t = 1	t = 2	t = 3	t = 4	t = 1	t = 2	t = 3	t = 4
fam1	1	2	1	3	0	0	0	0	0	0	0	0
fam2	7	5	7	6	7	6	7	2	3	5	3	10
fam3	15	22	16	20	26	17	23	22	17	19	10	24
fam4	0	0	1	1	1	1	0	1	1	1	0	0
fam5	1	1	0	0	0	0	0	0	0	0	0	0
fam6	5	1	9	6	0	0	0	0	0	0	0	0
fam7	10	30	19	41	12	20	19	53	18	13	27	19
fam8	14	12	8	22	15	11	24	19	8	8	17	19
fam9	10	26	10	31	15	10	16	24	7	12	9	20
fam10	32	27	53	67	44	50	30	66	40	45	53	18
fam11	0	0	0	0	3	6	4	4	3	5	2	4
fam12	2	2	1	2	3	2	2	3	1	1	1	0
fam13	0	0	0	0	0	0	0	0	0	0	0	0
fam14	7	9	7	9	14	11	11	17	10	13	5	8
fam15	0	0	0	0	0	0	0	0	0	0	0	0
fam16	0	0	0	2	0	0	1	1	0	1	1	0
fam17	0	0	0	1	3	3	2	4	1	1	0	0
fam18	1	0	2	0	0	0	0	0	0	0	0	0
fam19	0	0	0	0	0	0	0	0	1	2	2	0
fam20	1	1	1	3	1	1	2	3	1	2	1	4
fam21	0	0	0	0	0	0	0	0	0	3	0	8
fam22	7	7	12	16	2	2	4	4	3	3	3	1
fam23	1	2	2	2	1	2	2	5	1	3	3	1
fam24	33	31	60	43	19	30	45	48	13	27	25	59
fam25	1	1	1	1	1	1	1	0	1	1	1	0
fam26	27	34	19	27	25	33	15	33	16	14	13	32

ANEXO B – EXPERIMENTOS COM VARIAÇÃO NOS PARÂMETROS CPLEX

De acordo com Atamtürk e Savelsberg (2005), os parâmetros que controlam o algoritmo *branch-and-cut* são ajustados de forma genérica. Dependendo da estrutura particular de alguns problemas, pode ser interessante um ajuste fino destes parâmetros.

Algumas etapas do algoritmo B&C incluem estratégias de pré-processamento, relaxação, heurísticas e planos de corte, conforme figura B1. Para tentar melhorar a solução do modelo ‘GLSP Sequências Dependentes’ obtida pelo CPLEX foram realizados testes, alterando alguns parâmetros relacionados aos métodos de solução disponíveis no CPLEX. A primeira alteração realizada foi modificar o parâmetro que controla as opções de seleção de nós (*mipemphasis*, *nodeselect*, *bbinterval*, Tabela B1). Outro experimento consistiu em desligar as estratégias de pré-processamento (*presolve* = 0, tabela B1). Para avaliar a influência dos planos de corte na solução do modelo, primeiramente todos foram desligados (*mipcuts-1*, tabela B1). Em seguida foram realizados experimentos ligando os planos de corte um a um (*mipcuts-1cliquecuts1*, *mipcuts-1covercuts1*, etc. tabela B1). Finalmente, foram desligados um a um os planos de cortes (*cliquecuts-1*, *covercuts-1*, etc. tabela B1).




Figura B1. Etapas na resolução de problemas inteiros no CPLEX.

Os experimentos foram realizados com os dados *mesA*, *mes3* e *mes7*, pois a solução do modelo GLSP usando o software AMPL/CPLEX não encontra a solução ótima.

Tabela B1. Resultados das variações nos parâmetros CPLEX.						
Opções de seleção de Nós						
	mesA			mes3		
	f.o.	tempo	gap	f.o.	tempo	gap
mipemphasis0	3519	331 s	16,58%	4425	227 s	3,24%
mipemphasis1	3519	767 s	14,87%	4425	218 s	3,24%
mipemphasis2	3519	631 s	16,51%	4425	187 s	3,24%
mipemphasis3	3643	1869 s	19,45%	4476	523 s	4,35%
mipemphasis4	3519	306 s	16,58%	4425	261 s	3,21%
<hr/>						
nodeselect1	3519	331 s	16,58%	4425	227 s	3,24%
nodeselect2	3519	392 s	16,58%	4425	459 s	3,24%
nodeselect3	3519	2775 s	16,65%	4445	32 s	3,69%
<hr/>						
nodeselect2 bbinterval3	3519	596 s	16,58%	4425	184 s	3,24%
nodeselect2 bbinterval10	3519	428 s	16,58%	4425	145 s	3,24%
<hr/>						
presolve0	3461	889 s	15,39%	4445	104 s	3,69%
<hr/>						
Opções de Planos de Corte						
mipcuts-1	3519	331 s	16,58%	4425	227 s	3,24%
mipcuts0	3519	340 s	16,58%	4425	198 s	3,24%
mipcuts1	3445	1927 s	14,89%	4445	53 s	3,69%
mipcuts2	3459	1671 s	15,18%	4425	77 s	3,24%
mipcuts-1 cliquecuts1	3445	1106 s	15,00%	4445	123 s	3,69%
mipcuts-1 cliquecuts2	3445	1384 s	15,00%	4445	127 s	3,69%
mipcuts-1 covercuts1	3445	1226 s	15,00%	4445	107 s	3,69%
mipcuts-1 covercuts2	3445	1250 s	15,00%	4445	126 s	3,69%
mipcuts-1 disjcuts1	3445	1220 s	15,00%	4445	106 s	3,69%
mipcuts-1 disjcuts2	3445	79 s	14,95%	4445	14 s	3,69%
mipcuts-1 disjcuts3	3519	554 s	16,69%	4445	135 s	3,69%
mipcuts-1 flowcuts1	3453	772 s	15,19%	4425	721 s	3,24%
mipcuts-1 flowcuts2	3519	605 s	16,77%	4425	721 s	3,24%
mipcuts-1 flowpathcuts1	3445	1272 s	15,00%	4445	122 s	3,69%
mipcuts-1 flowpathcuts2	3445	1047 s	15,00%	4445	132 s	3,69%
mipcuts-1 fraccuts1	3445	1410 s	14,87%	4445	113 s	3,69%
mipcuts-1 fraccuts2	3772	1695 s	22,10%	4425	226 s	3,24%
mipcuts-1 gubcuts1	3445	1246 s	15,00%	4445	129 s	3,69%
mipcuts-1 gubcuts2	3445	1163 s	15,00%	4445	113 s	3,69%
mipcuts-1 impliedcuts1	3445	1196 s	15,00%	4446	113 s	3,69%
mipcuts-1 impliedcuts2	3445	1159 s	15,00%	4446	121 s	3,69%
mipcuts-1 mircuts1	3445	277 s	15,00%	4446	175 s	3,69%
mipcuts-1 mircuts2	3445	382 s	15,00%	4446	161 s	3,69%
<hr/>						
cliquecuts-1	3519	340 s	16,58%	4425	197 s	3,24%
covercuts-1	3519	362 s	16,58%	4425	194 s	3,24%
disjcuts-1	3519	351 s	16,58%	4425	182 s	3,24%
flowcuts-1	3519	386 s	16,52%	4425	197 s	3,24%
flowpathcuts-1	3519	379 s	16,58%	4425	186 s	3,24%
fraccuts-1	3445	1121 s	14,89%	4445	183 s	3,69%
gubcuts-1	3519	438 s	16,58%	4425	201 s	3,24%
impliedcuts-1	3519	367 s	16,58%	4425	185 s	3,24%
mircuts-1						

Opções de seleção de Nós			
	mes7		
	f.o.	tempo	gap
mipemphasis0	10851	2998 s	14,43%
mipemphasis1	10934	3568 s	15,08%
mipemphasis2	10732	3491 s	13,49%
mipemphasis3	2305		59,71%
mipemphasis4	10851	1755 s	14,43%
<hr/>			
nodeselect1	10851	2998 s	14,43%
nodeselect2	10851	975 s	14,43%
nodeselect3	11034	1820 s	15,85%
<hr/>			
nodeselect2 bbinterval3	10729	3245 s	13,45%
nodeselect2 bbinterval10	10851	1687 s	14,43%
<hr/>			
presolve0	1106	3352 s	16,07%
<hr/>			
Opções de Planos de Corte			
mipcuts-1	10851	2998 s	14,43%
mipcuts0	10851	3244 s	14,43%
mipcuts1	10934	1798 s	15,08%
mipcuts2	11168	994 s	16,86%
mipcuts-1 cliquecuts1	10934	1091 s	15,08%
mipcuts-1 cliquecuts2	10938	1004 s	15,08%
mipcuts-1 covercuts1	10934	1148 s	15,08%
mipcuts-1 covercuts2	10934	1117 s	15,08%
mipcuts-1 disjcuts1	10934	1123 s	15,08%
mipcuts-1 disjcuts2	10934	517 s	15,08%
mipcuts-1 disjcuts3	11034	2045 s	15,85%
mipcuts-1 flowcuts1	11034	2883 s	15,85%
mipcuts-1 flowcuts2	10934	3323 s	15,08%
mipcuts-1 flowpathcuts1	10934	1108 s	15,08%
mipcuts-1 flowpathcuts2	10934	1192 s	15,08%
mipcuts-1 fraccuts1	10851	2681 s	14,43%
mipcuts-1 fraccuts2	10851	507 s	14,43%
mipcuts-1 gubcuts1	10934	1137 s	15,08%
mipcuts-1 gubcuts2	10934	1100 s	15,08%
mipcuts-1 impliedcuts1	10934	1124 s	15,08%
mipcuts-1 impliedcuts2	10934	1106 s	15,08%
mipcuts-1 mircuts1	11034	1766 s	15,85%
mipcuts-1 mircuts2	11045	582 s	15,93%
cliquecuts-1	10851	2725 s	14,43%
covercuts-1	10851	2811 s	14,43%
disjcuts-1	10851	3310 s	14,43%
flowcuts-1	10851	3387 s	14,43%
flowpathcuts-1	10851	3170 s	14,43%
fraccuts-1	11034	1732 s	15,85%
gubcuts-1	10851	3392 s	14,43%
impliedcuts-1	10851	3193 s	14,43%
mircuts-1			

ANEXO C – RESULTADOS COMPLETOS DOS EXPERIMENTOS COM VARIAÇÃO DE PARÂMETROS

Tabela C1. Perturbação nos custos de estocagem (Teste 1).

	aumento de 10%			aumento de 50%			aumento de 100%		
	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
GLSP exato									
f.o.	3871	4431	11134	5363	4782	12073	6809	5087	12881
c. estoques	3871	908	2825	5277	1285	3824	5889	1478	1883
c. h. extras	0	3523	8308	86	3497	8248	919	3609	10998
estoque	63	15	47	69	17	48	52	14	12
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0	4,1	9,67	0,1	5,01	9,6	1,07	4,2	12,8
t. prep.(h)	3,34	1,67	3,34	5,01	1,67	3,34	5,01	1,67	5,01
t. comp. (s)	3013	1385	3395	916	176	891	3406	1176	313
Gap (%)	16,67	25,83	13,05	17,99	21,97	6,7	14,13	15,71	5,38
GLSP RF variáveis									
f.o.	3799	4411	10974	5156	4717	11960	6809	5087	12881
c. estoques	3798	914	2725	5070	1109	3540	5889	1478	1883
c. h. extras	0	3497	8248	86	3609	8420	919	3609	10998
estoque	64	14	39	62	14	36	52	14	12
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0	4,07	9,6	0,1	4,2	9,8	1,07	4,2	12,8
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34	3,34	1,67	5,01
t. comp. (s)	1038	252	1240	2930	408	1637	2952	145	36
Gap (%)	13,9	24,58	11,38	13,89	20,2	5,47	13,6	15,41	5,13
GLSP RF periodos									
f.o.	3871	4425	11330	5263	4717	11960	6988	5087	12881
c. estoques	3871	816	3047	5177	1109	3540	6902	1478	1883
c. h. extras	0	3609	8283	86	3609	8420	86	3609	10998
estoque	63	14	47	61	14	36	61	14	12
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0	4,2	9,64	0,1	4,2	9,8	0,1	4,2	12,8
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34	3,34	1,67	5,01
t. comp. (s)	1025	1937	1035	620	1316	441	354	285	656
Gap (%)	16,65	25,73	14,55	16,34	20,89	5,82	16,33	15,7	5,38

Tabela C1. Perturbação nos custos de estocagem (Teste 1) (continuação).

	aumento de 10%			aumento de 50%			aumento de 100%		
	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
ATSP sub rotas									
f.o.	3790	4411	10442	5144	4117	11287	6809	5210	11985
c. estoques	3789	914	2245	5058	1109	3090	5889	1713	1524
c. h. extras	0	3495	8197	86	3609	8197	919	3497	10371
estoque	64	15	39	62	14	30	52	17	12
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0	4,07	9,54	0,1	4,2	9,54	1,07	4,07	12,07
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34	3,34	1,67	5,01
n. iterações	1	60	86	74	68	62	48	156	95
nº sub-rotas	6	305	452	323	329	346	205	681	518
t. comp. (s)	3580	3584	3558	2103	3580	3571	3527	3600	2738
ATSP <i>patching</i>	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	3790	4411	10442	5144	4117	11258	6809	5087	11895
c. estoques	3789	914	2245	5058	1109	3061	5889	1478	1524
c. h. extras	0	3497	8197	86	3609	8197	919	3609	10371
estoque	64	15	39	62	14	39	52	14	12
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0	4,07	9,54	0,1	4,2	9,54	1,07	4,2	12,07
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34	3,34	1,67	5,01
n. iterações	1	1	1	1	1	1	1	1	1
nº sub-rotas	6	7	8	5	8	9	6	10	7
t. comp. (s)	121	1528	10	9	18	237	5,48	4	10
GLSP períodos	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	3328	3349	10924	4506	3786	11395	6709	4332	12348
c. estoques	3242	1201	2616	4420	1638	4521	6366	2184	2618
c. h. extras	86	2148	8308	86	2148	6874	344	2148	9709
estoque	63	23	84	63	23	52	53	23	25
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,1	2,5	9,67	0,1	2,5	8	0,4	2,5	11,3
t. prep.(h)	0	0	3,34	0	0	1,67	0	0	1,67
t. comp. (s)	1866	838	3398	2052	1565	2816	1291	454	1668
Gap (%)	3,06	2,35	11,38	2,39	1,43	1,14	12,85	1	1,13

Tabela C1. Perturbação nos custos de estocagem (Teste 1) (continuação).

ATSP períodos	aumento de 10%			aumento de 50%			aumento de 100%		
	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	3328	3321	9293	4506	3779	10178	5970	4332	10973
c. estoques	3242	1259	2423	4420	1717	3304	5626	2184	2037
c. h. extras	86	2062	6874	86	2062	6874	344	2148	8936
estoque	63	23	82	63	20	49	38	23	22
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,1	2,4	8	0,1	2,4	8	0,4	2,5	10,4
t. prep.(h)	0	0	1,67	0	0	1,67	0	0	1,67
n. iterações	96	194	133	74	156	180	188	48	215
n° sub-rotas	395	771	633	299	649	802	684	209	970
t. comp. (s)	158	3513	3509	59	2114	1226	159	302	272
GLSP exato	aumento de 200%			aumento de 400%			aumento de 800%		
	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	8753	5409	13685	9944	5643	14665	10801	5989	15075
c. estoques	4800	425	2171	1868	513	513	0	0	923
c. h. extras	3952	4983	11513	8076	5129	14151	10801	5989	14151
estoque	26	2	7	5	1	1	0	0	1
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	4,6	5,8	13,4	9,4	5,97	16,47	12,57	6,97	16,47
t. prep.(h)	5,1	1,67	5,01	5,01	3,34	6,68	6,68	3,34	6,68
t. comp. (s)	101	137	219	168	33	2619	1085	124	2936
Gap (%)	5,75	9,61	7,61	8,97	2,59	9,76	13,29	8,18	12,23
GLSP RF variáveis	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	8753	5409	13685	9944	5643	14665	10801	5989	15075
c. estoques	4800	425	2171	1868	513	513	0	0	923
c. h. extras	3952	4983	11513	8076	5129	14151	10801	5989	14151
estoque	26	2	7	5	1	1	0	0	1
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	4,6	5,8	13,4	9,4	5,97	16,47	12,57	6,97	16,47
t. prep.(h)	3,34	1,67	3,34	5,01	3,34	1,67	5,01	3,34	6,68
t. comp. (s)	927	45	207	52	79	2534	419	406	2797
Gap (%)	3,01	9,19	7,6	8,83	2,58	9,79	13,29	8,18	12,23

Tabela C1. Perturbação nos custos de estocagem (Teste 1) (continuação).

GLSP RF periodos	aumento de 200%			aumento de 400%			aumento de 800%		
	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	8753	5409	13685	9944	5643	15109	10801	5989	16484
c. estoques	4800	425	2171	1868	513	3423	0	0	923
c. h. extras	3952	4983	11513	8076	5129	11685	10801	5989	15560
estoque	26	2	7	5	1	6	0	0	1
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	4,6	5,8	13,4	9,4	5,97	13,6	12,57	6,67	18,11
t. prep.(h)	5,01	3,34	5,01	5,01	3,34	5,01	5,01	5,01	8,35
t. comp. (s)	235	161	359	736	195	472	355	250	414
Gap (%)	5,75	9,62	7,61	8,97	2,59	12,44	13,29	8,19	19,73
ATSP sub rotas	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	8753	5409	12651	9944	5643	14017	10801	5989	14942
c. estoques	4800	425	2168	1868	513	1695	0	0	1847
c. h. extras	3952	4983	10482	8076	5129	12321	10801	5989	13094
estoque	26	2	11	5	1	5	0	0	2
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	4,6	5,8	12,2	9,4	5,97	14,34	12,57	6,97	15,24
t. prep.(h)	3,34	3,34	5,01	5,01	1,67	6,68	5,01	5,01	6,68
n. iterações	2	113	50	75	35	177	279	220	88
n° sub-rotas	4	532	283	337	186	588	1073	933	444
t. comp. (s)	2	3524	70	208	38	2315	3560	2807	3560
ATSP <i>patching</i>	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	8753	5409	12651	9944	5643	14017	10801	5989	14942
c. estoques	4800	425	2168	1868	513	1695	0	0	1847
c. h. extras	3952	4983	10482	8076	5129	12321	10801	5989	13094
estoque	26	2	11	5	1	5	0	0	2
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	4,6	5,8	12,2	9,4	5,97	14,34	12,7	6,97	15,24
t. prep.(h)	5,01	1,67	5,01	5,01	1,67	6,68	5,01	5,01	6,68
n. iterações	1	1	1	1	1	1	1	2	1
n° sub-rotas	4	4	8	8	5	7	5	12	7
t. comp. (s)	0,97	25	0,9	1	0,72	3	1,16	16	14

Tabela C1. Perturbação nos custos de estocagem (Teste 1) (continuação).

GLSP períodos	aumento de 200%			aumento de 400%			aumento de 800%		
	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	8553	4911	13024	9328	5496	13230	9773	5499	13640
c. estoques	1923	1131	308	736	513	513	923	0	923
c. h. extras	6530	3780	12716	8592	4983	12716	8850	5499	12716
estoque	11	8	1	2	1	1	1	0	1
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	7,6	4,4	14,8	10	5,8	14,8	10,3	6,4	14,8
t. prep.(h)	0	0	3,34	1,67	0	3,34	1,67	0	3,34
t. comp. (s)	1493	12	596	865	40	371	852	37	2,99
Gap (%)	2,41	0,45	2,92	2,96	0	0	4,18	0	6,95
ATSP períodos	mesA	mes3	mes7	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	8453	4911	11992	9328	5496	13230	9773	5499	14134
c. estoques	1923	1131	3056	736	513	513	923	0	1847
c. h. extras	6530	3780	8936	8592	4983	12716	8850	5499	12287
estoque	11	8	17	2	1	1	1	0	2
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	7,6	4,4	10,4	10	5,8	14,8	10,3	6,4	13,49
t. prep.(h)	0	0	1,67	1,67	0	3,34	1,67	0	3,34
n. iterações	179	131	255	139	21	45	91	94	84
n° sub-rotas	677	546	1110	532	109	252	422	394	442
t. comp. (s)	50	73	463	129	4	68	15	25	41

Tabela C2. Perturbação na capacidade (Teste 2).

	redução de 10%			redução de 20%		
	mesA	mes3	mes7	mesA	mes3	mes7
GLSP exato						
f.o.	21185	20526	23815	44123	38437	38935
c. estoques	1389	103	1011	2331	1418	1869
c. h. extras	19796	20423	22803	41792	38295	37066
estoque	15	1	13	36	2	33
pendentes	0	0	0	0	0	0
h. extras (h)	23,04	23,77	26,54	48,64	44,57	43,14
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34
t. comp. (s)	303	1089	2470	238	1091	3042
Gap (%)	18,18	7,49	13,66	8,58	3,73	9,61
GLSP RF variáveis						
f.o.	20711	20526	23573	43556	38437	38774
c. estoques	915	103	941	1764	1418	1708
c. h. extras	19796	20423	22631	41792	38295	37066
estoque	11	1	12	32	2	31
pendentes	0	0	0	0	0	0
h. extras (h)	23,04	23,77	26,34	48,64	44,57	43,14
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34
t. comp. (s)	341	110	549	528	3096	1366
Gap (%)	16,16	7,49	13,67	7,35	0,98	9,25
GLSP RF periodos						
f.o.	21969	20731	23814	43641	38437	39322
c. estoques	1829	308	1182	1849	1418	2256
c. h. extras	20140	20423	22631	41792	38295	37066
estoque	19	3	13	32	2	35
pendentes	0	0	0	0	0	0
h. extras (h)	23,44	23,77	26,34	48,64	44,57	43,14
t. prep.(h)	1,67	1,67	3,34	3,34	1,67	3,34
t. comp. (s)	993	186,5	1121	493	716,1	889,3
Gap (%)	21,08	8,41	13,67	7,57	3,73	10,5
ATSP sub rotas						
f.o.	20556	20526	23573	43559	38437	38774
c. estoques	770	103	941	1767	1418	1708
c. h. extras	19796	20423	22631	41792	38295	37066
estoque	10	1	12	32	2	31
pendentes	0	0	0	0	0	0
h. extras (h)	23,04	23,77	26,34	48,64	44,57	43,14
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34
n. iterações	89	113	17	30	230	108
nº sub-rotas	398	502	95	143	942	535
t. comp. (s)	2825	79,9	407	383	1223	1729

Tabela C2. Perturbação na capacidade (Teste 2) (continuação).

ATSP <i>patching</i>	redução de 10%			redução de 20%		
	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	20556	20526	23573	43559	38437	38774
c. estoques	770	103	941	1767	1418	1708
c. h. extras	19796	20423	22631	41792	38295	37066
estoque	10	1	12	32	2	31
pendentes	0	0	0	0	0	0
h. extras (h)	23,04	23,77	26,34	48,64	44,57	43,14
t. prep.(h)	3,34	1,67	3,34	3,34	1,67	3,34
n. iterações	1	1	1	1	1	1
nº sub-rotas	8	7	7	4	4	4
t. comp. (s)	288	0,5	3	4,4	1,2	0,58
GLSP períodos	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	17454	18988	22550	40405	37002	38509
c. estoques	528	0	1009	1483	1418	1443
c. h. extras	16926	18988	21540	39922	36860	37066
estoque	9	0	16	30	2	21
pendentes	0	0	0	0	0	0
h. extras (h)	19,7	22,1	25,07	45,3	42,9	43,14
t. prep.(h)	0	0	1,67	0	0	3,34
t. comp. (s)	2834	34,5	2921	1261	28	2563
Gap (%)	0,71	0	8,83	0,16	0	8,61
ATSP períodos	mesA	mes3	mes7	mesA	mes3	mes7
f.o.	17448,5	18988,3	21830,2	40404,9	37001,5	37031,2
c. estoques	522,3	0	633,6	1483,1	1418	1400
c. h. extras	16926,2	18988,3	21196,5	39921,8	36859,7	35631
estoque	8	0	15	30	2	20
pendentes	0	0	0	0	0	0
h. extras (h)	19,7	22,1	24,67	45,3	42,9	41,47
t. prep.(h)	0	0	1,67	0	0	1,67
n. iterações	18	131	160	39	150	47
nº sub-rotas	77	558	744	167	638	267
t. comp. (s)	18	28		8	33	279

Tabela C3. Perturbação na demanda (Teste 3).

GLSP exato	concentrada em t=4			dados aleatórios limites reais				
	mesA	mes3	mes7	ale1	ale2	ale3	ale4	ale5
f.o.	67886	70619	59887	19701	4794	8891	13031	23803
c. estoques	67800	67955	53099	1371	4793	2587	410	890
c. h. extras	86	2664	6788	19563	0	6303	12620	22913
estoque	1409	1324	1012	1	82	17	4	9
pendentes	0	0	0	0	0	0	0	0
h. extras (h)	0,1	3,1	7,9	22,769	0	7,34	14,69	26,67
t. prep.(h)	1,67	1,67	1,67	6,68	8,35	3,34	6,68	5,01
t. comp. (s)	181	528	516	1877	2431	2418	1056	3050
Gap (%)	0,08	0,36	0,62	15,27	33,53	36,35	21,24	15,8
GLSP RF var.	mesA	mes3	mes7	ale1	ale2	ale3	ale4	ale5
f.o.	67886	70647	59887	20621	4216	8188	12414	25068
c. estoques	67800	67811	53099	137	4216	936	410	890
c. h. extras	86	2835	6788	20483	0	7252	12003	24178
estoque	1409	1322	1012	1	80	11	4	9
pendentes	0	0	0	0	0	0	0	0
h. extras (h)	0,1	3,3	7,9	23,84	0	3,34	13,97	28,14
t. prep.(h)	1,67	1,67	1,67	6,68	3,34	8,44	5,01	5,01
t. comp. (s)	122	116	317	1266	775	1362	1663	942
Gap (%)	0,08	0,33	0,64	14,58	9,74	29,64	10,92	15
GLSP RF per.	mesA	mes3	mes7	ale1	ale2	ale3	ale4	ale5
f.o.	67886	70619	59887	20929	4264	8210	12414	-
c. estoques	67800	67955	53099	445	4263	958	410	-
c. h. extras	86	2664	6788	20483	0	7252	12003	-
estoque	1409	1324	1012	4	81	9	4	10
pendentes	0	0	0	0	0	0	0	1
h. extras (h)	0,1	3,1	7,9	23,84	0	8,44	13,97	28,14
t. prep.(h)	1,67	1,67	1,67	5,01	5,01	3,34	5,01	6,68
t. comp. (s)	259,9	74,5	535	684	1470	988	1254	1282
Gap (%)	0,08	0,36	0,62	15,84	11,1	29,88	10,92	62,21
ATSP sub rotas	mesA	mes3	mes7	ale1	ale2	ale3	ale4	ale5
f.o.	67886	70619	59887	20621	4210	8196	12414	25048
c. estoques	67800	67955	53099	137	4210	944	410	870
c. h. extras	86	2664	6788	20483	0	7252	12003	24178
estoque	1409	1324	1012	2	81	11	4	13
pendentes	0	0	0	0	0	0	0	0
h. extras (h)	0,1	3,1	7,9	23,84	0	8,44	13,97	28,14
t. prep.(h)	1,67	1,67	1,67	3,34	5,51	3,34	5,01	3,34
n. iterações	1	10	14	324	59	81	609	53
n° sub-rotas	0	19	36	1840	385	504	3163	352
t. comp. (s)	0,23	5	359	3352	3600	3600	3600	3458

Tabela C3. Perturbação na demanda (Teste 3) (continuação).

ATSP <i>patching</i>	concentrada em t=4			dados aleatórios limites reais				
	mesA	mes3	mes7	ale1	ale2	ale3	ale4	ale5
f.o.	67886	70619	59887	20621	4199	8188	12414	25048
c. estoques	67800	67955	53099	137	4198	936	410	870
c. h. extras	86	2664	6788	20483	0	7252	12003	24178
estoque	1409	1324	1012	2	80	11	4	13
pendentes	0	0	0	0	0	0	0	0
h. extras (h)	0,1	3,1	7,9	23,84	0	8,44	13,97	28,14
t. prep.(h)	1,67	1,67	1,67	3,34	3,34	3,34	5,01	3,34
n. iterações	1	1	1	1	1	1	1	1
nº sub-rotas	0	2	5	11	7	10	4	2
t. comp. (s)	0,23	1	0,37	5	23	3	0,56	18
GLSP períodos	mesA	mes3	mes7	ale1	ale2	ale3	ale4	ale5
f.o.	67831	70367	59537	19186	3947	6630	11113	-
c. estoques	67745	69250	54124	137	3947	787	544	-
c. h. extras	86	1117	5413	19049	0	5843	10568	-
estoque	1397	1347	1012	1	79	15	7	19
pendentes	0	0	0	0	0	0	0	4
h. extras (h)	0,1	1,3	6,3	22,17	0	6,8	12,3	33,95
t. prep.(h)	3,34	0	0	3,34	1,67	1,67	1,67	10,2
t. comp. (s)	296	1509	3584	705	1567	18,81	3251	2389
Gap (%)	0	0	0,06	8,2	4,13	13,26	0,49	89,51
ATSP períodos	mesA	mes3	mes7	ale1	ale2	ale3	ale4	ale5
f.o.	67830	70367	59514	19186	3885	6630	11113	23359
c. estoques	67745	69250	54101	137	3885	787	544	616
c. h. extras	86	1117	5413	19049	0	5843	10568	22743
estoque	1397	1347	1013	1	78	15	7	6
pendentes	0	0	0	0	1	0	0	0
h. extras (h)	0,1	1,3	6,3	22,17	0	6,8	12,3	26,47
t. prep.(h)	0	0	0	3,34	1,67	1,67	1,67	3,34
n. iterações	2	3	1	167	281	160	262	67
nº sub-rotas	2	4	5	961	1563	908	1444	455
t. comp. (s)	0,26	0,5	0,28	217	2401	3594	409	472

Tabela C1. Perturbação na demanda (Teste 3) (continuação).

	dados aleatórios - U (0,50)									
GLSP exato	aleat1	aleat2	aleat3	aleat4	aleat5	aleat6	aleat7	aleat8	aleat9	aleat10
f.o.	35749	33785	-	939	37045	56065	30205	-	25941	-
c. estoques	519	2132	-	937	753	830	1385	-	3981	-
c. h. extras	35230	31652	-	0	36292	55235	28819	-	21958	-
estoque	10	44	54	19	12	9	28	208	68	7
pendentes	0	0	8	0	0	0	0	5	0	1
h. extras (h)	41,0	36,8	0,0	0,0	42,2	64,3	33,5	81,4	25,6	140,2
t. prep.(h)	10,0	13,4	13,4	15,0	8,4	11,7	10,0	13,4	16,7	10,0
t. comp. (s)	2225	1489	1162	2340	1777	2731	2059	1704	3456	3555
Gap (%)	23,4	32,2	99,4	61,7	16,3	9,5	25,7	81,0	29,7	37,8
GLSP RF var.	aleat1	aleat2	aleat3	aleat4	aleat5	aleat6	aleat7	aleat8	aleat9	aleat10
f.o.	34411	32221	2772	756	39258	57636	30163	-	21302	-
c. estoques	205	2449	2772	755	576	0	2316	-	3198	-
c. h. extras	34205	29771	0	0	38681	57635	27847	-	18103	-
estoque	2	25	52	18	9	1	34	53	55	6
pendentes	0	0	0	0	0	0	0	7	0	2
h. extras (h)	39,81	34,65	0	0	45,02	67,08	32,41	75,98	21,07	140,45
t. prep.(h)	6,7	8,4	6,7	8,4	10,0	6,7	6,7	6,7	8,4	8,4
t. comp. (s)	2650	1994	1154	2409	968	1166	2382	2792	1557	2248
Gap (%)	15,4	21,7	9,0	33,0	18,9	10,0	19,6	56,1	10,2	40,4
GLSP RF per.	aleat1	aleat2	aleat3	aleat4	aleat5	aleat6	aleat7	aleat8	aleat9	aleat10
f.o.	37190	33640	2771	-	39283	57636	32310	-	23043	-
c. estoques	301	3868	2769	-	600	0	1566	-	3500	-
c. h. extras	34179	29771	0	-	38681	57635	30742	-	19538	-
estoque	36	34	52	26	10	0	22	65	60	12
pendentes	0	0	0	3	0	0	0	7	0	5
h. extras (h)	39,8	34,7	0,0	0,0	45,0	67,1	35,8	82,7	22,7	146,2
t. prep.(h)	6,7	8,4	13,4	11,7	10,0	10,0	10,0	13,4	11,7	13,4
t. comp. (s)	1660	2147	1617	2210	2518	1172	2101	3160	2633	2608
Gap (%)	21,7	25,0	9,2	99,8	19,0	10,0	25,1	57,3	17,1	64,8
ATSP sub	aleat1	aleat2	aleat3	aleat4	aleat5	aleat6	aleat7	aleat8	aleat9	aleat10
f.o.	34205	30721	2770	756	36625	56201	29341	-	21302	-
c. estoques	0	2383	2769	755	813	0	1393	-	3198	-
c. h. extras	34205	28336	0	0	35812	56200	27847	-	18103	-
estoque	0	41	52	14	13	1	26	74	55	6
pendentes	0	0	0	0	0	0	0	7	0	2
h. extras (h)	39,8	33,0	0,0	0,0	41,7	65,4	32,4	76,0	21,1	138,8
t. prep.(h)	6,7	6,7	3,3	5,0	6,7	5,0	6,7	6,7	8,4	6,7
n. iterações	57	57	359	227	42	211	40	42	41	60
nº sub-rotas	407	415	2161	1452	282	1333	275	305	293	388
t. comp. (s)	3600	3600	3500	3480	3577	3553	3600	3600	3600	3600

Tabela C1. Perturbação na demanda (Teste 3) (continuação).

	dados aleatórios - U (0,50)									
ATSP <i>patching</i>	aleat1	aleat2	aleat3	aleat4	aleat5	aleat6	aleat7	aleat8	aleat9	aleat10
f.o.	34205	30721	2770	756	36625	56201	29240	-	21302	-
c. estoques	0	2383	2769	755	813	0	1392	-	3198	-
c. h. extras	34205	28336	0	0	35812	56200	27847	-	18103	-
estoque	0	41	52	14	13	0	25	71	55	6
pendentes	0	0	0	0	0	0	0	7	0	1
h. extras (h)	39,8	33,0	0,0	0,0	41,7	65,4	32,4	76,0	21,1	0,8
t. prep.(h)	6,7	6,7	5,0	5,0	6,7	5,0	6,7	6,7	6,7	6,7
n. iterações	1	1	1	1	1	1	1	1	1	1
n° sub-rotas	7	8	3	10	7	9	3	7	7	12
t. comp. (s)	77	3600	3,2	5,3	23	2	3600	3600	369	3600
GLSP períodos	aleat1	aleat2	aleat3	aleat4	aleat5	aleat6	aleat7	aleat8	aleat9	aleat10
f.o.	34411	29603	2770	756	35689	54766	28728	-	21570	-
c. estoques	205	2700	2769	755	1286	0	2316	-	3466	-
c. h. extras	34205	26902	0	0	34402	57765	26412	-	18103	-
estoque	2	29	54	19	21	1	34	82	62	7
pendentes	0	0	0	0	0	0	0	7	0	2
h. extras (h)	39,8	31,3	0,0	0,0	40,0	63,7	30,7	74,3	21,1	138,8
t. prep.(h)	6,7	5,0	8,4	6,7	5,0	6,7	5,0	5,0	10,0	6,7
t. comp. (s)	1235	1945	2269	2841	3272	1797	3397	3205	3507	3370
Gap (%)	15,42	14,81	9,17	33,38	10,8	5,24	15,71	56,64	11,4	41,91
ATSP períodos	aleat1	aleat2	aleat3	aleat4	aleat5	aleat6	aleat7	aleat8	aleat9	aleat10
f.o.	32976	29603	2770	756	35693	54766	28728	-	21302	-
c. estoques	205	2700	2769	755	1315	0	2316	-	3198	-
c. h. extras	32770	26902	0	0	34377	54765	26412	-	18103	-
estoque	2	29	49	13	21	0	34	47	55	7
pendentes	0	0	0	0	0	0	0	7	0	2
h. extras (h)	38,1	31,3	0,0	0,0	40,0	63,7	30,7	72,6	21,1	138,8
t. prep.(h)	5,0	5,0	6,7	6,7	5,0	5,0	5,0	3,3	6,7	6,7
n. iterações	116	160	262	55	116	175	116	121	117	135
n° sub-rotas	777	1051	1418	383	805	1037	758	785	737	864
t. comp. (s)	3458	3600	3548	1308	3600	1756	3483	3497	3513	3487

Tabela C4. Variáveis de lote relaxadas ($q_{is} \geq 0$).

GLSP exato	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	3402	16607	4269	8152	4281	3185	13476	10011	10795
c. estoques	3401	222	4269	5453	784	3182	4996	5139	2598
c. h. extras	0	16385	0	2698	3497	0	8480	4872	8197
estoque	62,2	3,7	89,0	110,0	15,2	16,7	106,0	106,5	38,3
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	19,1	0,0	3,1	4,1	0,0	9,9	5,7	9,5
t. prep.(h)	5,0	3,3	3,3	0,3	1,7	3,3	1,7	1,7	3,3
t. comp. (s)	385	367	218	436	90	173	159	3535	1218
Gap (%)	13,9	7,29	6,7	10,5	25,87	0,1	3,12	4,2	13,99
GLSP RF per.	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes5
f.o.	3402	16607	4269	8152	4281	3185	13476	10011	10739
c. estoques	3401	222	4269	5453	784	3182	4996	5139	2542
c. h. extras	0	16385	0	2698	3497	0	8480	4872	8197
estoque	62,2	3,7	89,0	110,0	15,2	16,7	106,0	106,5	32,2
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	19,1	0,0	3,1	4,1	0,0	9,9	5,7	9,5
t. prep.(h)	5,0	3,3	1,7	0,3	1,7	3,3	1,7	1,7	3,3
t. comp. (s)	1173	439	192	699	356	401	128	3535	695
Gap (%)	13,9	7,29	6,69	10,5	25,87	0,1	3,12	4,24	13,54
ATSP sub rotas	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	3401	16607	4269	8152	4281	3185	13476	10011	10223
c. estoques	3401	222	4269	5453	784	3182	4996	5139	2026
c. h. extras	0	16385	0	2698	3497	0	8480	4872	8197
estoque	62,2	3,7	89,0	110,0	15,2	16,7	106,0	106,5	38,7
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	19,1	0,0	3,1	4,1	0,0	9,9	5,7	9,5
t. prep.(h)	3,3	3,3	3,3	0,3	1,7	3,3	1,7	1,7	3,3
n. iterações	65	1	103	122	65	8	61	137	74
n° sub-rotas	281	42	519	608	333	52	314	633	365
t. comp. (s)	1881	167	213	257	248	6	2915	559	922

Tabela C4. Variáveis de lote relaxadas ($q_{is} \geq 0$).

ATSP <i>patching</i>	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	3401	16607	4269	8152	4281	3185	13476	10011	10223
c. estoques	3401	222	4269	5453	784	3182	4996	5139	2026
c. h. extras	0	16385	0	2698	3497	0	8480	4872	8197
estoque	62,2	3,7	89,0	110,0	15,2	16,7	106,0	106,5	38,7
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	19,1	0,0	3,1	4,1	0,0	9,9	5,7	9,5
t. prep.(h)	3,3	3,3	3,3	0,3	1,7	3,3	1,7	1,7	3,3
n. iterações	1	1	1	1	1	1	1	1	1
n° sub-rotas	5	5	6	3	6	2	4	6	7
t. comp. (s)	9,39	1	32	39	27	0,88	0,93	7	18,65
GLSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	3360	15396	3983	7647	3173	3182	13476	10031	9831
c. estoques	3360	446	3983	6384	1111	3182	4996	5159	3069
c. h. extras	0	14950	0	1263	2062	0	8480	4872	6762
estoque	56,7	10,0	86,3	140,9	23,5	16,7	106,0	106,5	49,7
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	17,4	0,0	1,5	2,4	0,0	9,9	5,7	7,9
t. prep.(h)	0,0	3,4	1,7	1,7	0,0	0,0	1,7	1,7	1,7
t. comp. (s)	2060	538	3087	1524	342	1169	228	995	2092
Gap (%)	12,8	0,0	0,0	4,6	0,0	0,0	3,1	4,4	5,6
ATSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	2990	15396	3983	7647	3173	3182	13056	9587	9031
c. estoques	2990	446	3983	6384	1111	3182	6011	6150	2269
c. h. extras	0	14950	0	1263	2062	0	7045	3437	6762
estoque	63,9	10,6	88,1	140,9	23,5	16,7	131,0	131,5	46,7
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	17,4	0,0	1,5	2,4	0,0	8,2	4,0	7,9
t. prep.(h)	0,0	3,4	0,0	1,7	0,0	0,0	0,0	0,0	1,7
n. iterações	56	17	22	254	43	99	20	55	208
n° sub-rotas	238	60	123	1171	212	452	116	265	892
t. comp. (s)	8,4	2	4,2	2860	7	22	3,68	9,54	2398

Tabela C5. Geração de tempos de preparação aleatórios (Teste 5).

Tempos de preparação aleatórios, simétricos que obedecem a desigualdade triangular									
GLSP	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	-	-	-	-	33883	-	-	-
c. estoques	-	-	-	-	-	5141	-	-	-
c. h. extras	-	-	-	-	-	28737	-	-	-
estoque	-	-	-	-	-	87	-	-	-
pendentes	-	-	-	-	-	0	-	-	-
h. extras (h)	-	-	-	-	-	33,5	-	-	-
t. prep.(h)	-	-	-	-	-	50,9	-	-	-
t. comp. (s)	-	-	-	-	-	3223	-	-	-
Gap (%)	-	-	-	-	-	99,1	-	-	-
GLSP RF	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	-	-	-	-	77173	-	-	-
c. estoques	-	-	-	-	-	16066	-	-	-
c. h. extras	-	-	-	-	-	60102	-	-	-
estoque	-	-	-	-	-	273	-	-	-
pendentes	-	-	-	-	-	1	-	-	-
h. extras (h)	-	-	-	-	-	69,95	-	-	-
t. prep.(h)	-	-	-	-	-	40,2	-	-	-
t. comp. (s)	-	-	-	-	-	3552	-	-	-
Gap (%)	-	-	-	-	-	99,6	-	-	-
GLSP RF	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	-	-	-	-	-	-	-	-
c. estoques	-	-	-	-	-	-	-	-	-
c. h. extras	-	-	-	-	-	-	-	-	-
estoque	-	-	-	-	-	-	-	-	-
pendentes	-	-	-	-	-	-	-	-	-
h. extras (h)	-	-	-	-	-	-	-	-	-
t. prep.(h)	-	-	-	-	-	-	-	-	-
t. comp. (s)	-	-	-	-	-	-	-	-	-
Gap (%)	-	-	-	-	-	-	-	-	-
ATSP sub	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	16783	27143	17630	21158	21162	19185	27365	22577	26555
c. estoques	1064	0	648	1865	1000	19185	2394	1137	1219
c. h. extras	15717	27141	16980	19291	20160	0	24969	21439	25334
estoque	19	0	7	32	19	37	49	22	24
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	18,3	31,6	19,8	22,5	23,5	0,0	29,1	25,0	29,5
t. prep.(h)	23,4	18,5	24,4	22,6	22,2	20,3	20,8	21,0	23,3
n. iterações	12	6	25	40	29	40	21	40	25
nº sub-rotas	72	28	142	237	136	214	165	200	146
t. comp. (s)	1093	545	2277	3600	3600	2643	1917	3600	2286
Gap (%)	60,3	12,1	55,9	38,0	18,2	50,1	36,1	36,2	52,7

Tabela C5. Geração de tempos de preparação aleatórios (Teste 5) (continuação).

Tempos de preparação aleatórios, simétricos que obedecem a desigualdade triangular									
ATSP <i>patching</i>	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	16783	27143	17630	21158	18464	19185	27365	23840	26555
c. estoques	1064	0	648	1865	956	19185	2394	1563	1219
c. h. extras	15717	27141	16980	19291	17507	0	24969	22275	25334
estoque	19	0	7	32	20	37	49	30	24
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	18,3	31,6	19,8	22,5	20,4	0,0	29,1	26,1	29,5
t. prep.(h)	23,4	18,5	24,4	22,6	19,1	20,3	20,8	20,6	23,3
n. iterações	2	5	5	4	6	5	3	5	4
nº sub-rotas	54	44	62	57	45	68	75	59	56
t. comp. (s)	638	124	364	548	546	187	579	355	88
GLSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	-	-	-	-	-	-	-	-
c. estoques	-	-	-	-	-	-	-	-	-
c. h. extras	-	-	-	-	-	-	-	-	-
estoque	-	-	-	-	-	-	-	-	-
pendentes	-	-	-	-	-	-	-	-	-
h. extras (h)	-	-	-	-	-	-	-	-	-
t. prep.(h)	-	-	-	-	-	-	-	-	-
t. comp. (s)	-	-	-	-	-	-	-	-	-
Gap (%)	-	-	-	-	-	-	-	-	-
ATSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	14186	26992	13995	19834	17579	1830	24958	21002	23572
c. estoques	2232	0	1926	2734	321	1828	2355	976	1027
c. h. extras	11952	26990	12068	17099	17256	0	22601	20024	22543
estoque	33	0	36	43	5	36	50	16	23
pendentes	0	267,6	0	0	0	0	0	0	0
h. extras (h)	13,9	31,4	14,0	19,9	20,1	0,0	26,3	23,3	26,2
t. prep.(h)	18,9	18,3	18,6	20,1	18,8	18,2	18,1	19,3	19,8
n. iterações	6	3	16	79	6	27	37	47	58
nº sub-rotas	46	22	75	270	38	95	149	159	170
t. comp. (s)	182	1,58	489	2421	182	822	1131	1429	1780

Tabela C5. Geração de tempos de preparação aleatórios (Teste 5) (continuação).

	Tempos de preparação aleatórios 0 ou 1,67 - Uniform(0,4,1)								
GLSP exato	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	19323	28912	22459	29192	14652	4457	32847	26281	24164
c. estoques	5797	2790	1844	11001	2175	4067	5857	1147	4461
c. h. extras	13524	26120	20612	18189	12476	387	26988	25132	19702
estoque	109	34	24	178	27	72	83	12	57
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	15,7	30,4	24,0	21,2	14,5	0,5	31,4	29,3	22,9
t. prep.(h)	20,0	16,7	28,4	20,0	11,7	28,4	21,7	25,1	15,0
t. comp. (s)	3067	3328	2504	1419	2984	2141	2405	2804	2908
Gap (%)	83,0	47,2	82,3	75,0	78,3	92,8	60,3	63,5	65,1
GLSP RF var.	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	19557	21616	-	12133	12514	887	28887	15729	21663
c. estoques	7295	573	-	3479	3535	887	7637	4344	5604
c. h. extras	12261	21042	-	8652	8979	0	21248	11384	16058
estoque	98	12	-	61	39	16	103	73	47
pendentes	0	0	-	0	0	0	0	0	0
h. extras (h)	14,3	24,5	-	10,1	10,5	0,0	24,7	13,3	18,7
t. prep.(h)	3,3	11,7	-	10,0	8,4	3,3	15,0	8,4	11,7
t. comp. (s)	2971	2980	-	2899	3580	3242	3235	3485	3157
Gap (%)	83,2	29,3	-	39,7	74,6	63,3	54,8	39,1	61,1
GLSP RF per.	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	29532	41586	-	-	-	-	-	-
c. estoques	-	4279	7197	-	-	-	-	-	-
c. h. extras	-	25252	34385	-	-	-	-	-	-
estoque	-	70	77	-	-	-	-	-	-
pendentes	-	0	0	-	-	-	-	-	-
h. extras (h)	-	29,4	40,0	-	-	-	-	-	-
t. prep.(h)	-	15,0	43,4	-	-	-	-	-	-
t. comp. (s)	-	2770	2811	-	-	-	-	-	-
Gap (%)	-	48,3	90,4	-	-	-	-	-	-
ATSP sub rotas	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	3869	16772	6377	10678	8294	409	21010	10140	8985
c. estoques	3868	962	4168	6493	1094	408	3868	6703	3486
c. h. extras	0	15809	2208	4184	7200	0	17141	3437	5499
estoque	88	20	90	144	18	12	71	132	63
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	18,4	2,6	4,9	8,4	0,0	20,0	4,0	6,4
t. prep.(h)	6,7	5,0	6,7	5,0	6,7	3,3	11,7	0,0	0,0
n. iterações	2	3	3	1	1	2	1	4	2
n° sub-rotas	10	8	11	6	7	9	9	11	8
t. comp. (s)	472	19	3600	3600	3600	14	3600	3600	435
Gap (%)	0,0	0,0	12,7	0,5	12,1	0,0	1,5	0,8	3,4

Tabela C5. Geração de tempos de preparação aleatórios (Teste 5) (continuação).

	Tempos de preparação aleatórios 0 ou 1,67 - Uniform(0,4,1)								
ATSP <i>patching</i>	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	3868	16772	4799	7484	4011	409	13661	10140	9095
c. estoques	3868	962	4799	7484	1605	408	6272	6703	3596
c. h. extras	0	15809	0	0	2406	0	7389	3437	5499
estoque	88	20	100	162	31	12	129	132	61
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	18,4	0,0	0,0	2,8	0,0	8,6	4,0	6,4
t. prep.(h)	1,7	5,0	1,7	0,0	0,0	3,3	0,0	0,0	0,0
n. iterações	11	5	8	22	15	22	14	5	11
nº sub-rotas	24	10	19	49	41	42	40	12	28
t. comp. (s)	801	39	727	1997	1365	1131	1273	454	916
GLSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	38061	-	-	-	-	-	-	-
c. estoques	-	5452	-	-	-	-	-	-	-
c. h. extras	-	32607	-	-	-	-	-	-	-
estoque	-	81	-	-	-	-	-	-	-
pendentes	-	0	-	-	-	-	-	-	-
h. extras (h)	-	38,0	-	-	-	-	-	-	-
t. prep.(h)	-	25,1	-	-	-	-	-	-	-
t. comp. (s)	-	3535	-	-	-	-	-	-	-
Gap (%)	-	59,9	-	-	-	-	-	-	-
ATSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	3436	16514	4221	7457	3329	409	13352	9781	8800
c. estoques	3436	88	4221	7457	1267	408	6306	6344	3473
c. h. extras	0	15637	0	0	2062	0	7045	3437	5327
estoque	78	18	90	160	29	12	127	132	65
pendentes	0	0	0	0	0	0	0	0	0
h. extras (h)	0,0	18,2	0,0	0,0	2,4	0,0	8,2	4,0	6,2
t. prep.(h)	0,0	3,3	1,7	0,0	0,0	3,3	0,0	0,0	0,0
n. iterações	6	7	10	8	4	12	13	5	4
nº sub-rotas	11	13	19	24	17	35	27	13	15
t. comp. (s)	4	34	302	242	46	19	393	151	23

Tabela C5. Geração de tempos de preparação aleatórios (Teste 5) (continuação).

Tempos de preparação iguais a zero troca por 10 minutos (0,1667 hs)									
GLSP exato	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	30807	-	-	32221	15232	-	-	-
c. estoques	-	2524	-	-	4476	3148	-	-	-
c. h. extras	-	28281	-	-	27743	12082	-	-	-
estoque	-	29	-	-	79	50	-	-	-
pendentes	-	0	-	-	0	0	-	-	-
h. extras (h)	-	32,9	-	-	32,3	14,1	-	-	-
t. prep.(h)	-	19,5	-	-	20,7	22,9	-	-	-
t. comp. (s)	-	2466	-	-	3590	2980	-	-	-
Gap (%)	-	50,4	-	-	90,2	97,9	-	-	-
GLSP RF var.	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	-	-	-	-	-	-	-	-
c. estoques	-	-	-	-	-	-	-	-	-
c. h. extras	-	-	-	-	-	-	-	-	-
estoque	-	-	-	-	-	-	-	-	-
pendentes	-	-	-	-	-	-	-	-	-
h. extras (h)	-	-	-	-	-	-	-	-	-
t. prep.(h)	-	-	-	-	-	-	-	-	-
t. comp. (s)	-	-	-	-	-	-	-	-	-
Gap (%)	-	-	-	-	-	-	-	-	-
GLSP RF per.	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	-	-	-	-	-	-	-	-
c. estoques	-	-	-	-	-	-	-	-	-
c. h. extras	-	-	-	-	-	-	-	-	-
estoque	-	-	-	-	-	-	-	-	-
pendentes	-	-	-	-	-	-	-	-	-
h. extras (h)	-	-	-	-	-	-	-	-	-
t. prep.(h)	-	-	-	-	-	-	-	-	-
t. comp. (s)	-	-	-	-	-	-	-	-	-
Gap (%)	-	-	-	-	-	-	-	-	-
ATSP sub rotas	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	20785	-	14454	-	-	19301	-	17676
c. estoques	-	103	-	2875	-	-	2601	-	1314
c. h. extras	-	20682	-	11578	-	-	16698	-	16361
estoque	-	1	-	36	-	-	39	-	19
pendentes	-	0	-	0	-	-	0	-	0
h. extras (h)	-	24,1	-	13,5	-	-	19,4	-	19,0
t. prep.(h)	-	96,8	-	13,7	-	-	11,2	-	12,8
n. iterações	-	32	-	35	-	-	37	-	40
n° sub-rotas	-	131	-	187	-	-	170	-	223
t. comp. (s)	-	2902	-	3196	-	-	3380	-	3600
Gap (%)	-	3,4	-	23,7	-	-	13,7	-	19,1

Tabela C5. Geração de tempos de preparação aleatórios (Teste 5) (continuação).

Tempos de preparação aleatórios 0 ou 1,67 - Uniform(0,4,1)									
ATSP <i>patching</i>	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	20785	9162	14192	10692	1067	19050	15167	17489
c. estoques	-	103	3944	2899	691	1005	2691	2703	1557
c. h. extras	-	20682	5217	11292	10000	61	16358	12463	15931
estoque	-	1	68	38	11	19	51	48	23
pendentes	-	0	0	0	0	0	0	0	0
h. extras (h)	-	24,1	6,1	13,1	11,6	0,1	19,0	14,5	18,5
t. prep.(h)	-	96,8	10,7	13,3	10,3	12,3	10,8	10,5	12,3
n. iterações	-	1	1	1	1	1	1	1	1
nº sub-rotas	-	0	8	8	7	9	6	8	7
t. comp. (s)	-	3600	3460	3600	3600	3600	3600	3600	3600
GLSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	-	-	-	-	-	-	-	-
c. estoques	-	-	-	-	-	-	-	-	-
c. h. extras	-	-	-	-	-	-	-	-	-
estoque	-	-	-	-	-	-	-	-	-
pendentes	-	-	-	-	-	-	-	-	-
h. extras (h)	-	-	-	-	-	-	-	-	-
t. prep.(h)	-	-	-	-	-	-	-	-	-
t. comp. (s)	-	-	-	-	-	-	-	-	-
Gap (%)	-	-	-	-	-	-	-	-	-
ATSP períodos	mesA	mesB	mes1	mes2	mes3	mes4	mes5	mes6	mes7
f.o.	-	19493	7960	13161	9462	848	18335	-	15906
c. estoques	-	103	4174	3876	753	818	3697	-	893
c. h. extras	-	19390	3781	9284	8708	29	14637	-	15011
estoque	-	1	77	66	12	17	57	-	11
pendentes	-	0	0	0	0	0	0	-	0
h. extras (h)	-	22,6	4,4	10,8	10,1	0,0	17,0	-	17,5
t. prep.(h)	-	6,7	8,8	11,0	8,8	9,7	8,8	-	11,2
n. iterações	-	15	117	42	56	117	77	-	116
nº sub-rotas	-	65	488	195	257	510	336	-	510
t. comp. (s)	-	8,5	3513	1286	1713	3600	2365	-	3600