

**UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO**

**RICARDO ANTONIO LOPES MAIOLI**

**MODELAGEM DE UM SISTEMA DE  
PROGRAMAÇÃO DE PRODUÇÃO DE UMA  
INDÚSTRIA DE AUTOPEÇAS UTILIZANDO  
PROGRAMAÇÃO INTEIRA**

**Setembro de 2017**

**Itajubá, MG**

**UNIVERSIDADE FEDERAL DE ITAJUBÁ**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM**  
**ENGENHARIA DE PRODUÇÃO**

**RICARDO ANTONIO LOPES MAIOLI**

**MODELAGEM DE UM SISTEMA DE**  
**PROGRAMAÇÃO DE PRODUÇÃO DE UMA**  
**INDÚSTRIA DE AUTOPEÇAS UTILIZANDO**  
**PROGRAMAÇÃO INTEIRA**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do título de **Mestre em Ciências em Engenharia de Produção**

Área de Concentração: Modelagem, Otimização e Controle

Orientador: Prof. Rafael Coradi Leme, Dr.

**Setembro de 2017**

**Itajubá, MG**

*Dedico este trabalho aos meus pais Marcos e Maria, à minha irmã Patrícia, à minha namorada Lívia Bernardes e aos meus amigos de república por me apoiarem integralmente ao longo desta jornada.*

## AGRADECIMENTOS

Primeiramente, ao prof. Dr. Rafael Coradi Leme, amigo e orientador, pelas orientações e por todo conhecimento transmitidos durante vários anos de trabalho em conjunto.

Ao amigo Prof. João Batista Turrioni, por me apoiar e me ajudar mesmo nos momentos mais difíceis.

Ao professor José Leonardo Noronha, pelo apoio desde o primeiro dia que ingressei na UNIFEI.

Aos meus pais, Marcos Antonio Maioli e Maria Lopes Fajardo Maioli, por sempre estarem ao meu lado.

À minha irmã, Patrícia Lopes Maioli, pelos conselhos e pelo incentivo sempre presentes.

À minha namorada, Lívia Bernardes, pelo amor, compreensão, amizade e companheirismo.

Ao amigo Luciano Viveros, por todo o ensinamento durante meu período de estágio e por ter acreditado em mim no meu primeiro emprego.

Aos meus pais americanos, Nancy Allen, Daniel Allen, Dana Savage e Sam Savage, por tudo que me ensinaram.

Aos meus amigos americanos Ashley Woodle e Alex Dunn e franceses Hoang Tam, Oliver Yao e Ha mza, pelos bons momentos passados juntos.

A todos meus amigos de Itajubá e Ourinhos pela amizade desde sempre, especialmente ao Vinícius Rennó e Antonio Lima por estarem sempre ao meu lado no mestrado.

À República Grau Master, pelo excelente tempo em que passei lá.

À professora Andrea Cynthia Santos, pela ajuda e amizade e orientação durante a minha estadia na França.

Ao Rotary Internacional, por me ajudar a ser quem eu sou.

*“Quem sabe faz a hora, não espera acontecer”*

**Geraldo Vandré**

## RESUMO

A competitividade entre as empresas vem aumentando com o passar dos anos, isto porque a constante evolução tecnológica vem gerando grandes ganhos de produtividade nas diferentes áreas presentes nos negócios. Para se manter no mercado, portanto, as empresas vêm criando e desenvolvendo métodos e processos cada vez mais produtivos. Uma das áreas mais importantes é a da programação, uma importante parte do planejamento e controle da produção. A programação da produção é responsável por determinar a melhor alocação dos recursos e, se feita com as ferramentas corretas, podem trazer reduções de custos para as empresas. Essas diminuições podem vir do aproveitamento dos *setups* existentes nas máquinas, a partir de um decréscimo no atraso em peças, do melhor balanceamento das linhas, da diminuição dos custos totais e até estar presente no *lead time*. Por isso, o objetivo desta dissertação foi modelar um sistema de programação de produção com capacidade finita e com dados obtidos do ERP (Sistema utilizado para gerenciar as demandas existentes em uma operação) de uma empresa de autopeças situada no estado de Minas Gerais, Brasil, visando reduzir o número de atraso em peças e, conseqüentemente, diminuindo o custo de operação e de fretes extras. Para atingir esse objetivo, foi utilizado como base um modelo do tipo CLSP, do inglês *Capacitated Lot Sizing Problem*, que possui características específicas como capacidade finita, ser discreto, e possuir *setup* como parte importante de sua capacidade. O modelo, ainda, foi projetado com transferência de capacidade de um período para o outro, de forma a não perder os minutos restantes, como ocorre em modelos tradicionais de CLSP. Como houve o desenvolvimento matemático e a realização de testes posteriores, foi utilizado o método de pesquisa conhecido como modelagem e simulação, tradicionalmente composta de quatro etapas: Conceituação, modelagem, resolução através do programa e a implantação do sistema. A implantação do sistema a partir dos dados criados apresentou resultados satisfatórios gerando economia para os três tipos de modelos testados, para alta, média e baixa demandas. Para o caso de alta demanda, o modelo gerou uma economia de mais de cem mil reais em um ano, o que pode ser considerado uma grande economia para empresa caso a mesma tente implantar o sistema. Portanto, o modelo apresentou resultados positivos, demonstrando ganhos a partir de sua aplicação, e é considerado efetivo para o caso da empresa estudada. Apesar disto, muitos avanços podem ser ainda realizados com o modelo para que ele se torne mais completo. Por fim, o banco de dados obtido com presente estudo fornece informações de uma empresa real, caso seja necessário efetuar novos testes em outros modelos.

**Palavras-Chave:** CLSP, Programação da produção, MRP, Capacitado, Indústria Automobilística, Planejamento e controle da produção, *branch and bound*, otimização

## ABSTRACT

The competition in business world is getting bigger and bigger through the years, this occurs because the constant technological evolution is making productivity get higher every year in very different sectors of the economy. Therefore, to keep the business running the companies are creating and developing better processes and methods and one of the best examples of this evolution is in the production scheduling, one of the areas of the production planning and control sector. Production scheduling is responsible to determine the beginning and the end of the fabrication of the production orders and if is done with the right tools and the right knowledge can bring big productivity gains to the business. These gains can come from higher machine availability from setup optimizations in the periods, reduction of late finished goods, better line flows, lower operation costs and lead time and tardiness reduction. That is why the main objective of this dissertation is modeling a scheduling model with finite capacity and test with data obtained from an auto parts industry, located in the Minas Gerais state in Brazil, where the objective function wants to minimize the total late parts of the tested periods and reduce the losses with late shipping. To achieve the main objective was created a model based on the CLSP, Capacitated Lot Sizing Problem. It has special characteristics such as finite capacity, being a discrete model and has the setup option as a complicating factor for the capacity problem. The model was also projected with a special characteristic for the remaining times of the periods, if this happens this time goes to the another period to avoid losing capacity like in the common CLSP models. Because it was used the mathematical programming the research method known as modeling and simulation was used e it is composed of four parts: Contextualization, modeling, solving the model and the implementation. The implementation of the system, using the real collected data has proven to be very effective because the model has presented satisfactory results in the three kinds of tested demand, high, medium and low. In the high demand case the model has returned an economy of over one hundred thousand reais over one year that can be considered a big earning for the enterprise if it tries to apply the tool. Therefore, the model has returned high earnings and can be considered effective for the case of the studied business, although a lot of advance can be made in the model to get it more complete. Another important part is the data bank that can be used to test another models in another papers.

**Key-words:** CLSP, Production scheduling, MRP, Capacitated, Auto parts industry, Production planning and control, branch and bound, optimization.

## LISTA DE FIGURAS

Figura 2.1 - Gráfico do modelo EOQ .....	26
Figura 2.2- Método de busca em profundidade. Adaptado de Belfiore e Fávaro (2013)	36
Figura 2.3 – Método de busca em largura. Adaptado de Fávaro e Belfiore (2013). .....	37
Figura 2.4 - Método de busca nó mais promissor. Adaptado de Fávaro e Belfiore (2013). .....	37
Figura 3.1 - Modelo de Simulação .....	44
Figura 4.1 - Licenciamento de veículos no Brasil em 2016 .....	50
Figura 4.2 - Licenciamento de automóveis no Brasil desde 2011 .....	51
Figura 4.3 Código de importação do MATLAB .....	59
Figura 4.4 - Fluxograma para aquisição dos dados para o modelo. ....	59
Figura 4.5 - Vetores no Matlab.....	60
Figura 4.6 - Tabelas a serem feitas na P.O. ....	60
Figura 4.7 - Fluxograma de execução do modelo .....	60
Figura 5.1 - Comparação de demanda x capacidade para demanda alta. ....	64
Figura 5.2 - Utilização do modelo de otimização com custos iguais a 1. ....	67
Figura 5.3 - Evolução da produtividade no trabalho .....	68
Figura 5.4 – Comparação de demanda x capacidade – alta.....	73
Figura 5.5 – Comparação de demanda x capacidade – alta.....	74
Figura 5.6 - Comparação de demanda x capacidade para demanda média. ....	80
Figura 5.7 - Comparação de demanda x capacidade para demanda média. ....	83
Figura 5.8 - Comparação de demanda x capacidade para demanda média .....	86
Figura 5.9 - Comparação demanda x capacidade média .....	90
Figura 5.10 - Comparação demanda x capacidade .....	95
Figura 5.11 - Comparação demanda x capacidade baixa .....	97
Figura 5.12 - Comparação de demanda x capacidade baixa.....	101
Figura 5.13 - Comparação de demanda x capacidade baixa.....	104
Figura 5.14 - Comparação de demanda x capacidade - baixa .....	106



## LISTA DE TABELAS

Tabela 4.1 - Variação dos produtos de acordo com G e D.....	53
Tabela 4.2 - Organização da produção para o caso de demanda alta .....	55
Tabela 4.3 - Organização da produção para o caso de média demanda .....	56
Tabela 4.4 - Organização da produção para o caso de demanda baixa .....	57
Tabela 4.5 - Planilha excel com os dados prontos para importação para o Matlab.....	58
Tabela 5.1 - Demanda alta dos produtos dividida em períodos e famílias .....	62
Tabela 5.2 - Dados de produção para o modelo de alta demanda contando todos os setups .....	63
Tabela 5.3 - Modelo de programação atual da fábrica considerando aproveitamento de setups .....	63
Tabela 5.4 - Valores de produção por período e tipo .....	65
Tabela 5.5 - Atraso em cada período por tipo de produto .....	66
Tabela 5.6 - Ganhos computados com o uso do programa de otimização .....	69
Tabela 5.7 - Diferenças entre os custos de atraso para cada tipo de peça do sistema ....	70
Tabela 5.8 - Produção dividida por período e tipo .....	71
Tabela 5.9 - Atraso dividido por tipo e período .....	72
Tabela 5.10 - Ganhos computados com o uso do programa de otimização .....	73
Tabela 5.11 – Produção dividida pro tipo e período .....	75
Tabela 5.12 – Atraso dividido por tipo e período.....	75
Tabela 5.13 - Ganhos computados com o uso do programa de otimização .....	76
Tabela 5.14 - Demanda média dos produtos dividida em períodos e famílias.....	78
Tabela 5.15 - Dados de produção para o modelo atual contando todos os setups - média .....	79
Tabela 5.16 - Modelo de programação atual da fábrica considerando aproveitamento de setups- média .....	79
Tabela 5.17 - Valores de produção por período e tipo .....	81
Tabela 5.18 - Ganhos computados com o uso do programa de otimização .....	83
Tabela 5.19 - Valores de produção por período e tipo .....	85
Tabela 5.20 - Ganhos computados com o uso do programa de otimização .....	87
Tabela 5.21 - Valores de produção por período e tipo .....	88
Tabela 5.22 - Atraso em cada período por tipo .....	89
Tabela 5.23 - Ganhos computados com o uso do programa de otimização .....	91
Tabela 5.24 - Demanda baixa.....	92
Tabela 5.25- Dados de produção para o modelo atual contando todos os setups - baixa	93
Tabela 5.26 - Modelo de programação atual da fábrica considerando aproveitamento de setups (baixa).....	94
Tabela 5.27 - Valores de produção por período e tipo .....	96
Tabela 5.28 - Ganhos computados com o uso do programa de otimização .....	98
Tabela 5.29 - Valores de produção por período e tipo .....	99
Tabela 5.30 - Atraso em cada período por tipo .....	100
Tabela 5.31 - Ganhos computados com o uso do programa de otimização .....	101
Tabela 5.32 - Valores de produção por período e tipo .....	102
Tabela 5.33 - Atraso em cada período por tipo .....	103
Tabela 5.34 - Valores de produção por período e tipo .....	105
Tabela 5.35 - Ganhos computados com o uso do programa de otimização .....	107

Tabela 5.36 - Síntese dos resultados obtidos na demanda alta.....	108
Tabela 5.37 - Síntese dos resultados obtidos na demanda média.....	108
Tabela 5.38 - Síntese dos resultados obtidos na demanda baixa.....	108
Tabela 8.1 - Valores para a demanda alta.....	116
Tabela 8.2 - Valores para a demanda média.....	117
Tabela 8.3 - Valores para a demanda baixa.....	118

## LISTA DE QUADROS

Quadro 2.1 – Classificação das características do modelos de produção e de lot sizing	24
Quadro 2.2 - Parâmetros para o modelo CLSP .....	28
Quadro 2.3 - Resumo dos modelos avaliados.....	33

## LISTA DE ABREVIATURAS E SIGLAS

B.O.M – *Bill Of Materials*

CLSP – *Capacitated Lot Sizing Problem*

DLSP – *Dynamic Lot Sizing Problem*

ELSP – *Economic Lot Sizing Problem*

EOQ – *Economic Order Quantity*

ERP - *Enterprise Resource Planning*

GLSP – *General Lot Sizing Problem*

MPS – *Master Production Schedule*

MRP - *Materials Resource Planning*

PCP – *Planejamento e Controle da produção*

PI – *Programação Inteira*

PLSP – *Proportional Lot Sizing Problem*

WW – *Wagner Within*

WIP – *Work in process*

## Sumário

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>14</b>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA.....</b>	<b>20</b>
2.1	Materials resource planning .....	20
2.2	Características e classificação dos problemas de produção e de <i>lot sizing</i> .....	22
2.3	Modelos de lot sizing mais conhecidos .....	25
2.3.1	EOQ.....	25
2.3.2	WAGNER-WITHIN.....	26
2.3.3	CLSP.....	27
2.3.4	DLSP .....	29
2.3.5	CLSP CONTÍNUO.....	31
2.3.6	PLSP.....	31
2.3.7	GLSP .....	33
2.4	Modificações especiais existentes nos modelos .....	34
2.5	Métodos heurísticos x métodos exatos .....	35
2.5.1	Métodos de solução exatos .....	36
2.5.2	Heurísticas .....	39
<b>3</b>	<b>MÉTODO DE PESQUISA.....</b>	<b>41</b>
3.1	CLASSIFICAÇÃO DO TRABALHO DESENVOLVIDO .....	41
3.2	MÉTODO UTILIZADO .....	43
<b>4</b>	<b>MODELO E DADOS UTILIZADOS.....</b>	<b>46</b>
4.1	FORMULAÇÃO DO PROBLEMA.....	46
4.2	MODELAGEM MATEMÁTICO E SOLUÇÃO PELO MODELO.....	50
4.2.1	DADOS UTILIZADOS.....	50
4.2.2	SOLUÇÃO PELO MODELO .....	58
<b>5</b>	<b>RESULTADOS.....</b>	<b>61</b>
5.1	ANÁLISE DE DEMANDA ALTA.....	61
5.2	ANÁLISE DE DEMANDA MÉDIA .....	77
5.3	ANÁLISE DE DEMANDA BAIXA.....	91
<b>6</b>	<b>CONCLUSÃO .....</b>	<b>109</b>
<b>7</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>111</b>
<b>8</b>	<b>ANEXO .....</b>	<b>116</b>

# 1 INTRODUÇÃO

A revolução industrial, no século XVIII, foi um marco na evolução humana, pois, com ela, os itens que antes eram fabricados apenas por artesãos passaram a ser fabricados em uma escala maior e com preços menores. Essa mudança permitiu o acesso a grande parte da população a bens que antes eram muito caros ou difíceis de serem adquiridos.

Apesar dessa grande evolução, até meados de 1890, as fábricas eram pequenas e produziam suas peças no sistema de bateladas, ou seja, a maioria das peças fabricadas era igual e em lotes de grande quantidade. Isso quer dizer que o *mix*<sup>1</sup> de produção, ou seja, a gama de produtos que era fabricada por uma empresa, era muito pequeno. Por isso, a produção podia ser controlada apenas por poucas pessoas, que eram chamadas de contramestres ou simplesmente de encarregados (HERRMANN, 2006).

Porém, a partir do advento das peças intercambiáveis, partes que podem ser utilizadas em diversos produtos, a produtividade e o tamanho das empresas aumentaram de forma drástica, assim como o número de modelos a serem fabricados por cada planta. A produção, que antes era controlada apenas pelos encarregados, ou mestres de produção, tornou-se muito complexa para ser programada apenas por eles. Isso fez com que Frederick Taylor propusesse separar o planejamento da prática, criando assim os primeiros cargos de programadores de produção na história (TAYLOR, 2010).

A partir dessa separação, ocorreu o nascimento da programação da produção. Ela pode ser definida como a alocação dos recursos disponíveis para a produção, de forma a atingir algum critério de desempenho, ou ainda como a atividade responsável por alocar os recursos disponíveis para realizar as tarefas em um determinado tempo (CHENG, 2001; RODAMMER E JUNIOR, 1988).

Além disso, nessa época, também foi criada uma ferramenta para facilitar o planejamento e a programação da produção, o gráfico de Gantt, que foi desenvolvido por Henry Gantt. Segundo Herrmann (2006), Henry Gantt trabalhou com Taylor na Midvale Steel e foi o responsável por criar o primeiro gráfico especialmente para auxiliar na programação da produção. O gráfico de Gantt possui duas características. A primeira é a representação do tempo no gráfico, enquanto que a segunda é a divisão desse tempo no gráfico relativo à quantidade proporcional de tempo de cada operação. Esse gráfico acabou por ajudar muito a desenvolver essa área.

---

<sup>1</sup> Mix – Número de tipos de produtos a serem fabricados em determinado período (SLACK *et al.*, 2009).

Apesar da divisão de áreas na indústria e a invenção dos gráficos de Gantt terem contribuído para uma melhor programação da produção, a possibilidade de programadores encontrarem soluções viáveis para seus problemas de programação diários, semanais e mensais, ainda consistia de uma tarefa complexa. Isso porque, com o aumento do número de processos e produtos nas empresas o sistema manual tornou-se falho e sujeito a erros. Os erros cometidos na programação acabavam por gerar problemas de entrega para os clientes, o que, conseqüentemente ocasionava perda de dinheiro para os negócios. Para uma melhora do atendimento dos clientes e aumento do lucro foi necessário, portanto, desenvolver modelos para facilitar as decisões de programação, de modo que esses problemas fossem sanados (GUIMARAES *et al.*, 2015).

O desenvolvimento de diferentes modelos de programação levou as empresas a possuírem uma gestão mais eficiente dos recursos segundo Rodammer e Junior (1988). No entanto, foi somente com advento dos computadores, a partir da década de 50, que muitas funções anteriormente realizadas por pessoas puderam ser automatizadas e melhoradas. A automatização dessas funções, além de aumentar a velocidade da obtenção das informações no chão de fábrica, forneceu condições para os pesquisadores para métodos mais robustos para otimizar ainda mais a programação (HERMANN, 2006).

A partir desses avanços e de uma necessidade cada vez maior da indústria, o número de estudos para otimizar processos cresceu. Esses fatos levaram à criação de uma ciência para estudo de como os fenômenos podem ser melhorados. Essa ciência atualmente é chamada de pesquisa operacional e, segundo Castro (2007), é uma disciplina que fornece suporte à tomada de decisão na busca da melhor solução através da utilização dos modelos matemáticos.

Citando Castro (2007), a pesquisa operacional:

[...] é relacionada à sistematização das ações de controle e direcionamento dos processos que, conforme KRAJEWINSK e RITZMAN (1993) transformam as entradas (mão-de-obra, ativos, materiais, energia e capital) em saídas (produtos e/ou serviços) buscando maximizar os resultados da organização.

A pesquisa operacional pode ser definida de uma maneira prática como uma ferramenta para auxiliar as empresas a tomarem melhores decisões sobre o que fazer com os recursos disponíveis. Com uma melhor utilização dos recursos, os rendimentos podem ser aumentados e, conseqüentemente, pode também ser acrescido o lucro. Por isso, os estudos para a realização de uma melhor programação de produção podem ser determinantes para o sucesso ou falência de uma empresa.

De acordo com Belfiore e Fávaro (2013), a pesquisa operacional surgiu na Inglaterra durante a segunda guerra mundial, momento no qual um grupo de cientistas foi convocado para solução de problemas militares para uma melhor utilização dos recursos escassos. Como os resultados desses estudos foram positivos, a pesquisa operacional foi expandida para os Estados Unidos e, posteriormente, para outras regiões do mundo. Desde então, essa ciência vem sendo aplicada em diversos campos do conhecimento.

É possível observar, também, que cada vez mais a pesquisa operacional é utilizada em sistemas de programação da produção para gerar cronogramas de uma forma mais rápida e assertiva. Nos dizeres de Wolsey (2002), o aumento das pesquisas no campo de pesquisa operacional e a evolução dos sistemas permite, hoje, resolver problemas de programação através dela, utilizando *softwares* comerciais, ajudando assim não especialistas a programarem de uma forma mais efetiva.

Um dos métodos desenvolvidos com o auxílio de ferramentas da pesquisa operacional para programar melhor uma fábrica foi o MRP, do inglês, *Materials resource planning*, que é um sistema responsável por transformar as demandas finais existentes no MPS<sup>2</sup> em demandas de materiais e ordens de produção de processos anteriores. O seu uso industrial surgiu juntamente com seu aperfeiçoamento computacional, em meados da década de 70, e alterou drasticamente o modelo de programação até então existente. Isso porque ele forneceu a possibilidade dos programadores verificarem as ordens futuras e de saberem mais facilmente a localização no chão de fábrica das ordens já emitidas, permitindo realizar assim uma otimização da programação (HERRMANN, 2006).

Cumprir verificar que o algoritmo chave de um sistema de MRP é o *lot sizing*, que foi desenvolvido para definir tamanho de lote e programar a produção. Para realizar essas tarefas, o sistema de MRP geralmente utiliza um modelo desse algoritmo conhecido como *uncapacitated lot sizing*. Além desse, existe outro também conhecido como *capacitated lot sizing* (KIMMS, 1996).

Por sua vez, o *uncapacitated lot sizing* pode ser definido como um algoritmo que não utiliza o conceito de capacidade para realizar a programação, ou seja, a quantidade de tempo disponível para produzir o lote não é avaliada. Essa característica pode gerar diversos problemas na gestão de uma fábrica como, por exemplo, a ocorrência de dias com a necessidade de entrega

---

<sup>2</sup> *Master Production Schedule* – Sequência de peças com as respectivas datas de entrega para a produção



muito acima do normal, enquanto que em outros dias a ociosidade fica grande, desbalanceando a entrega, e gerando custos desnecessários para a produção.

Para sanar o problema acima descrito, foi criado, então, o *capacitated lot sizing*. Nesse algoritmo, o tempo de produção de cada item é confrontado com a capacidade existente em cada período, não permitindo que ela seja ultrapassada. Essa melhoria ajuda o algoritmo a se tornar mais apropriado para a programação, pois acompanha a realidade das fábricas, que possuem um determinado tempo para produzirem seus itens. Dessa forma, uma modelagem que utilize esse algoritmo possui mais chances de ser bem sucedida em ambientes reais. No entanto, muitas empresas ainda não utilizam esse modelo capacitado.

Para resolver essa questão, então, o presente trabalho possuiu como objetivo principal otimizar a programação de uma parte da produção de uma empresa de autopeças, localizada no sul de Minas Gerais. Para isso, desenvolveu uma modelagem do tipo com restrição de capacidade, utilizando o modelo CLSP (*Capacitated lot sizing problem*), com dados reais obtidos da empresa. O modelo CLSP possui a restrição de capacidade, visando eliminar o problema de atrasos em número de peças na linha de produção gerado por uma programação desbalanceada no sistema MRP<sup>3</sup>. Dessa forma, é possível reduzir os custos ocasionados por fretes-extra, além do desperdício de capacidade.

Outros objetivos do problema são: aumentar a capacidade da linha de produção sem realizar investimentos em M.O.D, maquinário e instalações e utilizar algoritmos para os programadores encontrarem a solução ideal de programação.

A escolha do setor automotivo para a pesquisa deu-se, em primeiro lugar, devido à sua importância no mercado mundial e brasileiro. No Brasil, esse mercado representa cerca de 4% de seu PIB<sup>4</sup> (Anfavea, 2016). Em segundo lugar, ante o número de postos de trabalhos gerados por esse ramo, que totalizou cerca de 144.510 empregos diretos em 2014, segundo dados obtidos da (Anfavea, 2016). Em terceiro lugar, em decorrência do lucro das montadoras que, junto com as empresas de autopeças, somou US\$ 117.536 milhões em 2014. Em quarto lugar, é importante ressaltar o total de investimentos do setor em 2014, totalizando US\$ 6.727 bilhões (ANFAVEA, 2016).

Como uma ramificação importante do setor automotivo, o setor de autopeças foi escolhido devido ao fato que esse tipo de indústria, diferentemente das montadoras, possuem uma organização da produção do tipo *job-shop*. Nesse tipo de organização, várias máquinas

---

<sup>3</sup> MRP - *Materials Resource Planning*- Sistema para planejamento de pedido de materiais

<sup>4</sup> Produto Interno Bruto – medida do valor de bens e serviços produzidos em um país em um ano

realizam diversas operações e os fluxos entre os diferentes produtos não são padronizados, devido à grande quantidade de clientes atendidos. Por isso, a criação de linhas específicas para determinados produtos fica impossibilitada, tornando a programação extremamente difícil (GRAVES, 1981).

Outro ponto importante para a determinação do estudo foi a posterior possibilidade de aplicação dos algoritmos desenvolvidos na empresa estudada, devido à necessidade da mesma de melhorar e do apoio dos envolvidos com o processo.

Para uma melhor condução do trabalho foram admitidas algumas limitações. Essas limitações são: realização da otimização para o um grupo de máquinas somente, limitação dos dias de análise do modelo a cinco e a não implantação do modelo dentro da indústria estudada.

Como ferramenta principal, foi utilizada a pesquisa operacional, mais precisamente a programação inteira. Esse método já possui diversas aplicações práticas na literatura. Uma dessas aplicações pode ser observada em Katok e Ott (2000), para os quais a definição dos tamanhos de lote de uma fábrica de latas de cerveja, semanalmente, ajuda cada uma das fábricas clientes a serem atendidas da melhor forma possível. A programação inteira, assim como o nome sugere, retorna valores inteiros, o que é essencial para o tipo problema estudado, pois o número de peças produzidas é sempre inteiro.

Assim como a utilização da pesquisa operacional, a opção pela modelagem utilizando o *lot sizing* pode ser justificada pela sua utilização em *softwares* comerciais. Além disso, esse algoritmo possui diversas modificações já estudadas, o que facilita a sua adaptação para o problema proposto.

Na parte de resultados, o presente trabalho apresenta como principal justificativa uma possibilidade real de redução de custos para empresa, sendo o mais importante deles a redução de fretes-extra devido ao atraso na fabricação de peças para os clientes. Outro ponto importante é que, segundo Mesquita e Castro (2008), uma otimização da programação pode ajudar a reduzir perdas importantes em uma empresa como altos *lead times* de produção, custos de estoque de matéria prima e produção, redução de possíveis atrasos no cumprimento dos prazos e agilidade na hora de responder a imprevistos. Por isso, devido ao grande número de ganhos possíveis, a modelagem estudada apresenta benefícios para a empresa estudada.

Além disso, o seguinte trabalho pode ajudar a aumentar a eficiência da indústria brasileira ao fomentar o uso da pesquisa operacional no Brasil de forma prática. Ademais, estudos podem ser realizados com os dados presentes no problema, permitindo assim uma contribuição de mais autores sobre o assunto.

Por último, a presente dissertação é dividida da seguinte forma: No capítulo dois é apresentada a revisão bibliográfica. No capítulo três é analisada a metodologia de pesquisa a fundo. No capítulo quatro são analisados os dados e a forma como eles foram adquiridos, além da apresentação da formulação do modelo. No capítulo cinco é analisada a aplicação do modelo e seus resultados para três tipos de demanda, baixa, média e alta. No capítulo seis é realizada uma breve conclusão sobre o trabalho. Nos capítulos sete e oito são apresentadas as referências bibliográficas e os dados anexos, respectivamente.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 Materials resource planning

O MRP pode ser considerado um modelo de múltiplos níveis em que as ordens de produção e de compra são liberadas a partir de fases definidas pelos diferentes tempos. Além disso, ele também é utilizado para programar os itens nas máquinas onde eles serão processados. Para realizar essa programação, o sistema utiliza um algoritmo conhecido como *lot sizing*. Apesar de possuir diferentes formas, no MRP tradicional o *lot sizing* possui a característica de não considerar a capacidade por período como uma restrição, sendo conhecido como não capacitado (POCHET, 2001; DREXL E KIMMS, 1997).

Como o algoritmo possui essa restrição, apesar de programar os itens nas operações, demandas maiores que a capacidade em algumas operações podem ocorrer. Quando isso ocorre, o *lot sizing*, gera planos não viáveis para a produção, que torna *softwares* de MRP falhos na prática. Para sanar esse problema, uma solução foi criar no último passo do *software* um retrabalho da primeira solução encontrada, para que as restrições de capacidade iniciais sejam atingidas. O *lot sizing* capacitado visa corrigir esse problema (BUSCHKHUL *et al.*, 2010; POCHET, 2001).

Outro tipo de algoritmo de *lot sizing* introduzido no sistema MRP foi o PLSP (*Proportional Lot Scheduling Problem*), que, além de programar a produção, busca sequenciá-la. Para que isso aconteça, é necessário que haja a criação de regras para sequenciar ordens no processo anterior, sendo, geralmente criadas regras baseadas nos tempos de processamento pré-definidos das operações. Como o algoritmo PLSP original serve para apenas uma máquina, existem variações para permitir sua utilização no caso da existência de diversas máquinas. (STADTLER, 2013; TEMPELMEIER E COPIL, 2015).

Por fim, um último tipo de algoritmo que deve ser citado é que o MLCLSP, do inglês *Multi Level Capacitated Lot Sizing Problem*, o qual pode ser considerado a base teórica do MRP (HAASE, 1994; STADTLER, 2011).

Além do algoritmo de *lot sizing*, para o MRP funcionar é necessário o MPS, do inglês *Master Production Schedule*. O MPS é um documento gerado a partir do plano de produção. Esse programa possui o objetivo de guiar as ações da empresa em um determinado horizonte de tempo, podendo ser de semanas a meses. Para isso, esse documento transmite as demandas

do cliente para a fábrica definindo, portanto, o número de peças necessárias e as datas de entrega (LUIZ, 2012; DREXL E KIMMS, 1997).

Ainda segundo Luiz (2012), para a criação do MPS são necessárias algumas informações além do plano de produção. Essas informações são cedidas por diferentes áreas da empresa e são: previsão de entrega dos itens finais de forma individual, encomendas de clientes e do estoque, níveis atuais de estoque e restrições de capacidade existentes na área produtiva. Sem alguma dessas informações, o MPS pode ficar incompleto e gerar inconsistências na programação, como por exemplo, o esquecimento de pedido de algum cliente.

Ademais, outro documento essencial para o funcionamento do MRP é o B.O.M., do inglês *Bill of Materials*; o B.O.M. é o documento que define a sequência ou dependência de operações para se realizar o produto. Ele também pode ser chamado de instrução de produção (POCHET, 2001). Com a posse desses dois documentos, o MRP pode ser executado.

Assim, a execução do modelo consta de três passos primordiais, ignorando as restrições de capacidade. Existem, atualmente, três passos, eles são utilizados nos sistemas atuais de planejamento de recursos (DREXL E KIMMS, 1997).

No primeiro passo, começa-se pelos itens finais - para eles o algoritmo calcula o tamanho de lotes dos itens, sem utilizar as restrições de capacidade existentes no sistema de produção na prática. (DREXL E KIMMS, 1997; GRAVES, 1981).

Já no Segundo Passo, o resultado obtido no passo 1 geralmente excede as restrições de capacidade. Por isso, o sistema reorganiza as ordens de forma que a capacidade seja atendida, porém sem observar para as questões de precedência.

Por fim, no terceiro passo, as decisões de sequenciamento são tomadas e enviadas para o piso fabril. Ao realizar esses passos com os algoritmos não capacitados, os programas geram problemas como longos *lead times*, grandes quantidades de WIP<sup>5</sup>, além de possíveis ocorrências de entregas após o planejado (DREXL E KIMMS, 1997).

Mesmo com os problemas citados no parágrafo anterior, a utilização dos programas de MRP na indústria é largamente difundida e tende a ser cada vez mais presente com o avanço da computação. Isso porque o avanço dos algoritmos vai permitir cada vez mais uma melhora do sistema e, conseqüentemente, das áreas em que ele é utilizado, como, por exemplo, na produção.

---

<sup>5</sup> WIP – *Work in process* – Total de materiais a serem processados dentro de um determinado estabelecimento

## 2.2 Características e classificação dos problemas de produção e de *lot sizing*

Para uma melhor definição de qual modelo de *lot sizing* utilizar, os problemas de produção devem ser diferenciados em tipos distintos. Uma primeira classificação consistente de um sistema de produção ocorre em três etapas. A primeira etapa classifica através dos requisitos necessários, a segunda classifica através complexidade dos fluxos estudados, enquanto que a terceira define os indicadores de produção. Somente com essas três classificações é possível diferenciar os sistemas de produção e obter bons resultados de programação (GRAVES,1981).

A primeira etapa classifica os problemas de produção em relação ao modo que os pedidos são emitidos para a produção, existindo os tipos *closed shop* e *open shop*. No *open shop* não existem estoques, isto é, os pedidos vêm direto do consumidor e não do estoque. No *closed shop* os pedidos para fabricação advém dos estoques da fábrica. Por isso, o *open shop* pode ser considerado mais simples que o *closed shop*, isso porque os pedidos de fabricação são originados diretamente do MPS, ao passo que no *open shop* é necessária uma avaliação dos estoques de peças acabadas para emitir as ordens de fabricação (GRAVES,1981).

A segunda etapa classifica os problemas de produção avaliando a complexidade dos fluxos dos produtos. Nessa avaliação é considerada a quantidade de maquinário disponível e a quantidade de operações existentes.

Existem quatro tipos de classificação para esses problemas. O primeiro considera apenas uma operação e uma máquina, o segundo considera uma operação e várias máquinas, o terceiro considera várias operações considerando uma máquina para cada uma delas e o quarto e último considera várias operações e várias máquinas em cada operação (KARIMI *et al.*, 2003).

O primeiro e o segundo tipos de classificação dos fluxos, por possuírem apenas uma operação, são normalmente encontrados em instalações que trabalham com produtos acabados simples e que possuem demanda do tipo independente. A demanda do tipo independente ocorre quando o produto depende apenas dele para ser fabricado. Já o terceiro e quarto tipos de classificação são encontrados em sistemas fabris mais complexos, pois os produtos possuem diversos processos e esses processos sofrem uma relação de dependência com outros produtos no meio do processo, gerando demandas dependentes. Os produtos com demandas dependentes

sujeitam-se a processos e a outras peças no meio do fluxo para serem finalizados (SOX *et al.*, 1999; KARIMI *et al.*, 2003).

A terceira dimensão, comentada por Graves (1981), diz respeito aos indicadores de produção, que possuem duas grandes classes. A primeira, que analisa os custos da programação e a segunda, que avalia sua performance.

Os custos de programação medidos são os mais variados como, por exemplo, o *setup* e custos de manutenção de inventários, já os índices de performance vão desde a utilização de máquinas, passando por atraso médio até o número total de peças atrasadas. Segundo Graves (1981), na maioria das aplicações práticas são utilizados os dois indicadores, enquanto que na teoria geralmente só um deles é aplicado para cada estudo realizado.

Além das classificações citadas acima para os problemas de produção, existem outras quatro auxiliares para se caracterizar melhor um modelo de *lot sizing*. A primeira é relacionada à quantidade de itens fabricados por período, a segunda é relacionada à variação na demanda dos produtos, a terceira é relacionada ao número de itens fabricados e a quarta é relacionada à utilização da restrição de capacidade ou não dos períodos. A partir da definição dessas características, os pontos principais do *lot sizing* são definidos de uma forma mais completa (MADRONERO *et al.*, 2014).

A primeira classificação auxiliar diz respeito ao número de itens fabricados por período. Existem dois tipos de classificação, os modelos do tipo *big bucket* e os modelos do tipo *small bucket*. A classificação de *big bucket* ocorre quando os modelos conseguem produzir mais de um lote por período. Já os modelos *small bucket* ocorrem, quando apenas uma peça, ou apenas uma ordem é produzida por período (JANS E DEGREEVE, 2008).

A diferença entre as duas classificações reside no fato de que os modelos do tipo *big bucket* são considerados mais fáceis de se resolver, porém mais difícil de modelar que os de *small bucket*. Além disso, eles não servem para o sequenciamento das ordens. Já nos modelos *small bucket* o número de períodos é maior e equivale ao total do número de ordens, ou quantidade de peças a serem fabricadas. Por possuir essa característica os modelos *small bucket* podem ser utilizados para sequenciar a produção (BELVAUX E WOLSEY, 2000; POCHE, 2001).

A segunda classificação diferencia os modelos em relação a incerteza dos pedidos de produtos para a produção produzir, e classifica essas diferentes demandas em determinística ou estocástica. A demanda determinística ocorre quando a quantidade de itens a serem fabricados é conhecida previamente. A classificação pode ser dividida em demanda determinística estática,

que ocorre quando a demanda é sempre igual entre os períodos, e demanda determinística dinâmica, que ocorre quando a demanda varia de período para período. O segundo tipo, a demanda estocástica, ocorre quando não se conhece ao certo o número de itens a serem fabricados. Esse tipo de demanda pode ser modelado com ajuda de distribuições de probabilidade (MADRONERO *et al.*, 2014; KARIMI *et al.*, 2003).

A terceira classificação diferencia os modelos através do número de itens fabricados. Os modelos podem ser divididos entre os que apresentam apenas um tipo de produto e os que apresentam mais de um tipo de produto. Essa classificação é importante, pois, o aumento da variabilidade dos produtos torna o problema cada vez mais difícil de resolver (LUIZ, 2012; KARIMI *et al.*, 2003; HAASE; KIMMS, 1997; WOLSEY, 2002).

A quarta classificação diferencia os modelos em capacitado ou não capacitado. Para o modelo ser considerado como capacitado ele deve conter uma restrição que diz respeito a capacidade de produção do período. Caso ele não considere a restrição como uma restrição para efetuar a programação ele é considerado não capacitado.

Com as sete classificações propostas é possível definir o modelo a partir para a resolução do problema. Caso alguma dessas classificações não seja levada em conta, é possível que o modelo possua erros conceituais e não seja próprio para resolver o problema. Um exemplo desse tipo de erro seria projetar o modelo para apenas uma máquina ao passo que no ambiente industrial real existem várias. Tal erro acabaria com a utilidade do modelo desenvolvido. Apesar disso, vários algoritmos desenvolvidos podem ser utilizados para diferentes casos, como para uma ou mais máquinas.

Para finalizar, o Quadro 2.1 mostra um resumo das principais características dos problemas de produção e dos modelos de *lot sizing* verificadas na literatura.

Quadro 2.1 – Classificação das características do modelos de produção e de lot sizing

Característica	Classificação	
Número de itens	Um item	Múltiplos itens
Ordens de produção em um período	<i>Small Bucket</i>	<i>Big Bucket</i>
Número de estágios	Um estágio	Múltiplos estágios



Demanda	Determinística	Estocástica
Origem da demanda	<i>Open Shop</i>	<i>Closed Shop</i>
Número de máquinas	Uma máquina	Várias máquinas
Restrição de capacidade	Não capacitado	Capacitado

## 2.3 Modelos de lot sizing mais conhecidos

### 2.3.1 EOQ

O trabalho seminal sobre *lot sizing* é o de Harris (1913). Nesse trabalho, ele desenvolveu a fórmula do lote econômico de produção. Uma característica importante desse modelo é o fato de ele não considerar a capacidade da instalação como uma restrição; outra é que esse modelo trabalha somente com demanda determinística estática.

O modelo de *lot sizing* de Harris (1913) é popularmente conhecido como EOQ, do inglês *Economic order quantity*. Ele pode ser considerado um modelo de gestão de estoques que serve para que a equipe saiba qual o tamanho de lote mínimo para se trabalhar. Para se obter o tamanho ideal do lote para a produção são utilizados o custo do transporte, do inventário, da demanda e dos custos envolvidos para a abertura de uma nova ordem de produção (LUIZ, 2012).

Esse modelo pode ser representado de três formas. A primeira forma é a tabular, na qual são definidas equações e seus resultados são computados em uma tabela. O resultado da equação que apresentar o menor valor representa o tamanho de lote ideal. Na forma de representação gráfica ocorre um *trade-off* entre os custos de pedido e estocagem, o que apresenta o menor valor na curva. O ponto mais baixo da intersecção representa o tamanho de lote ideal. A forma gráfica pode ser vista na Figura 2-1. Na forma analítica, a Equação (2.1) é resolvida manualmente. Esse modelo foi o ponto de partida para a criação de outros tipos de *lot sizing* (LUIZ, 2012).




Figura 2.1 - Gráfico do modelo EOQ

Fonte: Castro (2007)

A fórmula criada por Harris (1913) é apresentada na Equação (2.1):

$$EOQ = \sqrt{\frac{2ds}{h}} \quad (2.1)$$

Nessa fórmula,  $d$  é a demanda de um ano inteiro,  $s$  é o custo para se criar a ordem de produção e  $h$  é o custo do estoque.

Esse modelo pode ser visto também nos artigos de Drexler e Kimms (1997), Karimi *et al.* (2003), Pochet (2001) e Marinelli *et al.* (2007).

### 2.3.2 WAGNER-WITHIN

A partir do trabalho realizado por Harris (1913) na determinação do EOQ, os pesquisadores desenvolveram um modelo de programação matemática no qual as demandas são dinâmicas, sendo que esse modelo ficou popularmente conhecido na literatura como o modelo de Wagner-Within. Esse modelo é baseado em duas premissas; a primeira diz respeito à soma dos estoques mais a produção no fim do período ser igual a zero é ótima e a segunda diz respeito à subdivisão do problema principal em problemas menores gera os mesmos resultados, ou seja, é utilizado um método diferente de solução. (CASTRO, 2007; WAGNER, 1958).

A formulação matemática do problema pode ser vista da Equação (2.2) até a Equação (2.6).

$$\min \sum_{t=1}^T (p(x_t) + he_t) \quad (2.2)$$

$$e_{t-1} + x_t - e_t = d_t \text{ para todo } t = 0, \dots, t \quad (2.3)$$

$$e_0 = e_T = 0 \text{ para todo } t = 0, \dots, t \quad (2.4)$$

$$x_t, e_T \geq 0 \text{ para todo } t = 0, \dots, t \quad (2.5)$$

Nessas fórmulas,  $d$  é a demanda do período  $p$  é o custo fixo de produção,  $h$  é o custo fixo do estoque,  $e$  é o estoque de cada período e  $x$  a produção de cada período.

A Equação (2.2) busca minimizar o custo total obtido pela soma do estoque mais o de produção, já a Equação (2.3) é do balanceamento de massa que equilibra os valores de produção, estoque final e inicial é bem definida em Belvaux e Wolsey (2000), já a Equação (2.4) define os estoques final e inicial como zero e atende a primeira premissa, por último a Equação (2.5) define as variáveis de produção e de estoques como maiores ou iguais a zero pois não existe a possibilidade de ocorrer valores de produção nem estoques negativos.

A equação de balanço, segundo Belvaux e Wolsey (2000) é da seguinte forma:

$$s_{t-1} + x_t = d_t + s_t \text{ para todo } t = 1, \dots, T \quad (2.6)$$

Essa Equação pode ser facilmente traduzida como o estoque final do período  $s_{t-1}$ , mais os valores de produção do período  $t$ , sendo igual ao estoque final do período  $t$  mais a demanda do período  $t$ .

Esse modelo pode ser encontrado também nos artigos de Drexl e Kimms (1997), Karimi *et al.* (2003), Jans e Degreave (2008), Pochet (2001)

### 2.3.3 CLSP

O terceiro modelo estudado é o CLSP, do inglês *Continuous Lot Sizing Problem*, e sua formulação pode ser encontrada em Tahar *et al.* (2006). Esse modelo tem como principais características a não utilização do *backlogging*, ou seja, a fabricação de peças depois da data de

entrega. Ele também possui uma demanda dinâmica e é capacitado, ou seja, respeita as restrições de capacidade (CASTRO, 2007).

O CLSP pode ser classificado como um modelo do tipo *big bucket*, com múltiplos itens, de um único nível e com uma demanda do tipo determinístico dinâmico. Os outros dois tipos de classificação podem ser variados.

As variáveis de decisão são as seguintes:  $I_{jt}$  é o inventário do item  $j$  no período  $t$ ,  $q_{jt}$  é a quantidade produzida de  $j$  no período  $t$  e  $x_{jt}$  é a variável binária que representa o *setup* quando é igual a 1. Os parâmetros para esse modelo podem ser vistos no Quadro 2.2.

Quadro 2.2 - Parâmetros para o modelo CLSP

Parâmetro	Significado
$C_t$	Capacidade de produção para o período $t$
$d_{jt}$	Demanda externa do item $j$ no período $t$
$h_j$	Custos de estocagem de $j$ no período $t$
$I_{j0}$	Estoque inicial de $j$ no período 0
$J$	Número de itens
$p_j$	Tempo necessário para se produzir um item de $j$
$s_j$	Custos de setup para o item $j$
$T$	Número de períodos

A modelagem matemática pode ser observada da Equação (2.7) até a Equação (2.12)

$$\text{Min} \sum_{j=1}^J \sum_{t=1}^T (s_j x_{jt} + h_j I_{jt}) \quad (2.7)$$

$$S. A. I_{jt} = I_{j(t-1)} + q_{jt} - d_{jt} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.8)$$

$$p_j q_{jt} \leq C_t x_{jt} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.9)$$

$$\sum_{j=1}^J p_j q_{jt} \leq C_t \text{ para todo } t = 1, \dots, T \quad (2.10)$$

$$x_{jt} \in \{0,1\} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.11)$$

$$I_{jt}, q_{jt} \geq 0 \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.12)$$

Onde a Equação (2.7) tem o objetivo de minimizar os custos relativos ao estoque e os setups, a Equação (2.8) é do balanceamento de massa que equilibra os valores de produção, estoque final e inicial, a Equação (2.9) restringe a produção do item somente se houver setup para ele no período, a Equação (2.10) torna o modelo capacitado, isto é, a produção não pode ser maior que o valor da capacidade, a Equação (2.11) define os valores para a variável binária de setup, com o setup ocorrendo quando ela é igual a 1 e a Equação (2.12) define as variáveis de produção e de estoques como maiores ou iguais a zero, pois não existe a possibilidade de ocorrer valores de produção nem estoques negativos.

Esse modelo pode ser visto também nos artigos de Marinelli *et al.* (2007), Haase (1996), Karimi *et al.* (2003), Lobo *et al.* (2007), Menezes *et al.* (2010), Helber *et al.* (2012)

### 2.3.4 DLSP

O DLSP, do inglês *Discrete lot sizing problem*, pode ser considerado como o modelo CLSP dividido em micro períodos, possuindo como principal restrição o “tudo ou nada”<sup>6</sup>. Essa restrição somente permite ao período  $t$  ser totalmente completado com produção ou ficar totalmente vazio. Além disso, somente é possível produzir um item por período, tornando esse modelo excelente para questões de sequenciamento da produção, diferente do modelo CLSP (DREXL; KIMMS, 1997).

Por esse modelo produzir apenas um item por período, ele é considerado do tipo *small bucket*, de múltiplos itens, único estágio e com a demanda dinâmica.

A principal diferença de modelagem entre o DLSP e o CLSP ocorre na Equação (2.15) do DLSP, na qual a inequação torna-se uma equação, ou seja, o valor de produção tem que ser igual ao da capacidade, caracterizando o “tudo ou nada”. Além disso, a Equação (2.16) garante que só um produto seja produzido por período. Para modelar o DLSP faz-se necessário, então, a criação de uma nova variável de decisão  $y_{jt}$ , binária, e que indique se a máquina está preparada para receber a próxima peça. (DREXL; KIMMS, 1997)

Após a criação da nova variável de decisão, é necessária a criação de um novo parâmetro. Esse parâmetro é o  $y_{j0}$ , binário, que indica se a máquina está preparada para receber a peça no período 1 ou não, com o valor de 1 equivalendo a condição de preparação finalizada.

---

<sup>6</sup> Restrição do tudo ou nada (DLSP) – Ou ocorre produção em todo o período ou não ocorre produção

A formulação matemática do modelo pode ser vista da Equação (2.13) até a Equação (2.19):

$$\text{Min} \sum_{j=1}^J \sum_{t=1}^T (s_j x_{jt} + h_j I_{jt}) \quad (1) \quad (2.13)$$

$$S.A. I_{jt} = I_{j(t-1)} + q_{jt} - d_{jt} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.14)$$

$$p_j q_{jt} = C_t x_{jt} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.15)$$

$$\sum_{j=1}^J y_{jt} \leq 1 \text{ para todo } t = 1, \dots, T \quad (2.16)$$

$$x_{jt} \geq y_{jt} - y_{j(t-1)} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.17)$$

$$y_{jt} \in \{0,1\} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.18)$$

$$I_{jt}, q_{jt}, x_{jt} \geq 0 \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.19)$$

Nesse modelo, a Equação (2.13) tem o objetivo de minimizar os custos relativos ao estoque e os *setups*, a Equação (2.14) é do balanceamento de massa, que equilibra os valores de produção, estoque final e inicial, a Equação (2.15) restringe a produção à totalidade do período com a igualdade, a Equação (2.16) garante que só exista um *setup* por período, a Equação (2.17) mostra se houve a mudança de produtos e como consequência um novo *setup*, a Equação (2.18) define os valores para a variável binária de *setup*, com o *setup* ocorrendo quando ela é igual a 1 e a Equação (2.19) define as variáveis de produção e de estoques como maiores ou iguais a zero pois não existe a possibilidade de ocorrer valores de produção nem estoques negativos.

Esse modelo pode ser visto também nos artigos de Jans e Degreave (2008), Salomon *et al.* (1991) e Ramezani *et al.* (2012).

### 2.3.5 CLSP CONTÍNUO

Segundo Drexl e Kimms (1997), o DLSP possui, em sua propriedade de tudo ou nada, mecanismos que permitem que sua resolução seja facilitada, porém, ele não corresponde totalmente à realidade vivida nas empresas. Por isso, um passo importante para que a realidade seja modelada de uma melhor maneira é CLSP contínuo, que, apesar de possuir a mesma formulação matemática que o DLSP, não utiliza o conceito de tudo ou nada.

A formulação matemática pode ser vista da Equação (2.20) até a Equação (2.26).

$$\text{Min} \sum_{j=1}^J \sum_{t=1}^T (s_j x_{jt} + h_j I_{jt}) \quad (2.20)$$

$$S.A. I_{jt} = I_{j(t-1)} + q_{jt} - d_{jt} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.21)$$

$$p_j q_{jt} \leq C_t y_{jt} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.22)$$

$$\sum_{j=1}^J y_{jt} \leq 1 \text{ para todo } t = 1, \dots, T \quad (2.23)$$

$$x_{jt} \geq y_{jt} - y_{j(t-1)} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.24)$$

$$y_{jt} \in \{0,1\} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.25)$$

$$I_{jt}, q_{jt}, x_{jt} \geq 0 \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.26)$$

Nesse modelo, a única Equação que difere do modelo DLSP é a (2.24), pois, nesse modelo, os tamanhos de lote podem ser de qualquer tamanho contínuo. Como ocorre no DLSP, as restrições de capacidade devem ser respeitadas (DREXL; KIMMS, 1997).

Esse modelo pode ser visto também no artigo de Marinelli *et al.* (2007)

### 2.3.6 PLSP

Apesar de o CLSP contínuo resolver o problema do tudo ou nada, a capacidade não utilizada totalmente em um período é perdida, o que leva a problemas na modelagem. Por isso,

o PLSP, do inglês *proportional lot sizing problem*, foi criado de forma que a capacidade restante de um período possa ser utilizada para um outro produto, permitindo assim a ocorrência de um setup no meio do período. Apesar disso, o *setup* somente pode ser mudado uma vez por período, ou seja, o *setup* inicial já deve ter acontecido quando começar um novo período  $t$ , por isso no máximo dois itens podem ser produzidos por período (DREXL E KIMMS, 1997).

A formulação do PLSP utiliza os mesmos parâmetros de decisão que o DLSP, sendo que a programação matemática pode ser vista nas Equações de (2.27) até (2.34).

$$\text{Min} \sum_{j=1}^J \sum_{t=1}^T (s_j x_{jt} + h_j I_{jt}) \quad (2.27)$$

$$\text{S.A. } I_{jt} = I_{j(t-1)} + q_{jt} - d_{jt} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.28)$$

$$p_j q_{jt} = C_t (y_{j(t-1)} + y_{jt}) \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.29)$$

$$\sum_{j=1}^J p_j q_{jt} \leq C_t \text{ para todo } t = 1, \dots, T \quad (2.30)$$

$$\sum_{j=1}^J y_{jt} \leq 1 \text{ para todo } t = 1, \dots, T \quad (2.31)$$

$$x_{jt} \geq y_{jt} - y_{j(t-1)} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.32)$$

$$y_{jt} \in \{0,1\} \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.33)$$

$$I_{jt}, q_{jt}, x_{jt} \geq 0 \text{ para todo } j = 1, \dots, J \text{ } t = 1, \dots, T \quad (2.34)$$

Apesar da maioria das equações serem parecidas com o modelo do CLSP contínuo, a Equação (2.29) restringe a produção de um item no período  $t$  somente se a máquina está preparada no começo do período ou no fim do período. Já a Equação (2.30) serve para que o modelo respeite as restrições de capacidade.

Esse modelo pode ser visto também nos artigos de Kimms (1996), Stadtler (2011) e Stadtler (2013), Tempelmeier e Copil (2015).



### 2.3.7 GLSP

Apesar dos avanços encontrados em modelos do tipo *small bucket*, para aplicações no mundo real as soluções encontradas são proibitivas devido ao alto tempo gasto para encontrar soluções viáveis. Porém, já foi provado que, com o uso de heurísticas, problemas de muitos períodos podem ser resolvidos. É importante ressaltar, também, que apenas poucos ajustes devem ser feitos para que propostas do tipo o CLSP possam resolver também problemas de sequenciamento (DREXL E KIMMS, 1997).

Outro tipo de modelo existente é o GLSP, que, apesar de possuir a mesma estrutura que o DLSP, tem em sua formulação um *slot*<sup>7</sup> especial para que o sequenciamento seja feito. Além disso, é possível que o usuário defina a quantidade máxima de lotes por período. Esse modelo também pode ser visto em Transchel *et al.* (2011).

Por último, segue a Quadro 2.3 com o resumo dos modelos de *lot sizing* avaliados no referencial bibliográfico desta dissertação. Essa tabela foi baseada em Salomon *et al.* (1991) e em Castro (2007).

Quadro 2.3 - Resumo dos modelos avaliados

Modelo	Características principais
EOQ	Não capacitado, <i>single item</i> , não se aplica
Wagner-Within	Não capacitado, <i>single item</i> , <i>big bucket</i>
CLSP	Capacitado, múltiplos itens, <i>big bucket</i>
DLSP	Capacitado, múltiplos itens, <i>small bucket</i>
CLSP Contínuo	Capacitado, múltiplos itens, <i>small bucket</i>
ELSP	Não capacitado, múltiplos itens, <i>small bucket</i>
PLSP	Capacitado, múltiplos itens, <i>big bucket</i>
GLSP	Capacitado, múltiplos itens, <i>big bucket</i>

<sup>7</sup> *Slot* – espaço no modelo para que o sequenciamento seja feito

## 2.4 Modificações especiais existentes nos modelos

Os modelos apresentados já possuem diversas características importantes, tais como *setup* e restrições de capacidade. Porém, existem modelos de *lot sizing* que possuem extensões importantes. Essas extensões ajudam a modelar os mais diversos casos existentes na produção, desde alterações no modo como o *setup* é computado até o modo de se calcular a demanda (JANS E DEGREAVE, 2008).

As alterações no *setup*, segundo Jans e Degreave (2008), advêm dos vários tipos de *setups* existentes. Um tipo de *setup* é do tipo *startup*, que no problema do tipo PLSP ocorre durante a troca de ferramentais, limpeza ou até o pré-aquecimento de máquina. Outro tipo de *setup* é o *carryover*, que modela a passagem de uma máquina preparada de um turno para outro, ganho inexistente para modelos comuns do CLSP, que mesmo produzindo no período o que a máquina acabou de produzir, considera o *setup* outra vez. Esse tipo de *setup* pode ser encontrado nos artigos de Haase e Kimms (1997), Haase (1994), Graves (1981) para o modelo PLSP.

Para sanar o problema da inexistência do *setup carryover* nos modelos CLSP, foi desenvolvido o CLSP com lotes interligado. Esse modelo permite reaproveitar o *setup* do turno anterior caso o produto a ser fabricada seja a mesmo do período anterior (JANS E DEGREAVE, 2008).

Outros tipos de extensões em *setups* incluem: o *setup* de aquecimento (*run up*), que consiste no tempo consumido depois dos *setups* até o equipamento atingir a velocidade normal de produção, o *setup* de campanha, que ocorre quando várias bateladas são feitas em sequência, exigindo um menor *setup* entre elas e os *setups* cíclicos, que sempre ocorrem no mesmo intervalo de tempo. Além disso, existem modelos em que o *setup* vai sendo reduzido conforme o conhecimento dos operadores aumenta (LUIZ, 2012; STADTLER, 2011; JANS E DEGREAVE, 2008; CHARLES *et al.*, 2012).

Outros tipos de modificações especiais encontradas nos modelos com relação à produção são o *backlogging* e a substituição dos produtos. O *backlogging*, que possui tradução literal para o português como “atraso na entrega do produto”, ocorre quando não entregar a demanda na data especificada é permitido. Nesse caso, ocorre uma penalidade na função objetivo devido a esse atraso permitido. A substituição dos produtos pode ocorrer para que a entrega para um cliente não seja prejudicada. Para isso comumente substitui-se um produto de

menor valor que está em falta por um de maior valor que está sobrando (JANS E DEGREAVE, 2008; HAASE; KIMMS, 1997).

Por último, existem modificações especiais nos modelos relacionadas aos estoques. A primeira delas é a dependência enquanto que a outra diz respeito à data de validade dos materiais. A primeira modificação ocorre quando há a necessidade de que diferentes produtos cheguem a uma operação para que ela seja realizada. A segunda alteração, que adiciona data de validade aos estoques, pode ser vista em modelos de empresas do ramo alimentício e que possuem produtos perecíveis. Os estoques ainda podem ter seus valores limitados a mínimo e máximo (MARINELLI *et al.*, 2007; SLACK *et al.*, 2009; SOX *et al.*, 1999).

Todas as modificações citadas aparecem em casos especiais, como por exemplo, a data de validade para modelos de empresas com itens perecíveis, porém elas são necessárias quando o processo modelo possui características especiais que não são abrangidas nos modelos comuns.

## 2.5 Métodos heurísticos x métodos exatos

A classificação dos métodos de solução dos modelos do *lot sizing* pode ser encontrada em dois trabalhos relevantes, o de Karimi *et al.* (2003) e o de Buschkuhl *et al.* (2010). No primeiro trabalho, os métodos de solução são divididos em três classes básicas: os métodos exatos, do qual o mais conhecido é o *branch and bound*, as heurísticas especializadas e as heurísticas baseadas em programação matemática. O segundo trabalho apresenta uma divisão um pouco diferente, contendo cinco partes. A primeira é dedicada às heurísticas de programação matemática, heurísticas lagrangianas, heurísticas de decomposição, e metaheurísticas e heurísticas *greedy*, apesar de nesse artigo o foco ser em para métodos exatos. Para essa revisão, foi proposto então realizar uma divisão básica em duas partes, a dos métodos de solução exatos, que buscam uma solução ideal e a dos métodos de solução heurísticos, que buscam soluções aproximadas. É importante observar que os métodos heurísticos não foram utilizados nesse trabalho.

### 2.5.1 Métodos de solução exatos

O algoritmo mais conhecido para resolução dos problemas de forma exata é o *branch and bound*, que pode ser traduzido do inglês como ramificar e podar, ou seja, o método enumera as soluções e depois corta as que são menos vantajosas ou que são inviáveis. Esse método pode ser visto para a resolução de problemas em Liaw *et al.* (2003). Apesar de o *branch and bound* resolver os problemas de forma exata, ele demanda um esforço computacional muito grande quando se trata de modelos com muitas variáveis (LUIZ, 2012).




Figura 2.2- Método de busca em profundidade. Adaptado de Belfiore e Fávoro (2013)

Esse algoritmo foi proposto em 1960, por Land e Doig (1960), para a solução de problemas com variáveis binárias e inteiras. Esse método pode ser classificado como um de divisão e conquista, no qual o problema original é ramificado em subproblemas menores e a cada solução desses problemas menores gera-se um limite inferior para a função objetivo. A combinação de várias dessas soluções gera a solução ideal (BELFIORE E FÁVARO, 2013).

Para o *branch and bound* realizar essas buscas, segundo Belfiore e Fávoro (2013), existem três tipos de estratégias: busca em profundidade, busca em largura e busca pelo nó mais promissor.

A busca em profundidade procura sempre pelo nó mais profundo da árvore até encontrar uma solução candidata e assim retorna ao topo da árvore, partindo para o outro lado. O esquema

de solução pode ser visto na Figura 2.2, no qual os números representam a sequência de solução dos subproblemas.

O segundo método de busca é o de largura e, diferentemente do primeiro método citado, ele escolhe sempre o nó mais perto do início da árvore. Outra característica desse método é que ele resolve todos os nós ramificados antes de abrir outros. O esquema de solução pode ser visto na Figura 2.3, onde assim como na Figura 2.2 os números representam a ordem de solução dos subproblemas.




Figura 2.3 – Método de busca em largura. Adaptado de Fávaro e Belfiore (2013).

O terceiro e último método, conhecido como o do nó mais promissor, busca sempre a solução a partir do nó com o melhor valor da função objetivo, podendo, portanto variar a ordem de solução dos problemas. Apesar das figuras mostrarem os problemas completos, a árvore de solução sempre pode ser podada quando um dos nós apresenta uma solução não factível. Um exemplo desse método pode ser visto na figura 2.4.




Figura 2.4 - Método de busca nó mais promissor. Adaptado de Fávaro e Belfiore (2013).

O algoritmo de solução do *branch and bound* pode ser visto dos passos 1 até 6. O passo 1 é conhecido como início, o passo 2 é conhecido como seleção, o passo 3 é conhecido como eliminação, o passo 4 é conhecido como ramificação os passos 5 e 6 como finais (BELFIORE E FÁVARO, 2013).

Início: Crie o problema de PI relaxado, ou seja, sem as restrições de integralidade que é representado por  $S_0$ . Depois crie uma lista  $L$  contendo  $L = \{S_0\}$ . Caso o problema for de minimização, assuma que  $z^* = +\infty$ , caso contrário inverta o sinal de  $z^*$ . Admita  $x^*$  como a solução incumbente.

- Passo 1: Caso ainda exista um subproblema na lista vá para o passo 2, senão pule para o passo 5.
- Passo 2: Remova um subproblema da lista de acordo com a estratégia de busca, e resolva-o por simplex à mão ou via computador.
- Passo 3a: Caso a solução obtida apresentar um valor pior ao igual a  $z^*$ , ou for infactível, descarte-a e retorne ao passo 1.
- Passo 3b: Se a solução não for inteira e o valor da função objetivo for melhor que  $z^*$ , vá para o passo 4.
- Passo 3c: Se a solução for inteira e o valor da função objetivo for melhor que  $z^*$ , atualize  $z^*$  e  $x^*$  e descarte da árvore cada problema com solução pior ou igual a nova solução. Como consequência os subproblemas gerados a partir desse nó também são eliminados.
- Passo 4: Para o problema que acabou de ser resolvido escolha uma variável  $x_i$  que não satisfaça as condições de integralidade, particione o problema em dois adicionando uma nova restrição para cada um deles e coloque os subproblemas na lista  $L$ .
- Passo 5: Se  $z^* = +\infty$  para um problema de minimização não existe solução factível, caso contrário pare, a solução  $x^*$  é ótima. Passe para o passo 6.
- Passo 6: Fim

O segundo algoritmo para resolução de forma exata é chamado de planos de corte, do inglês, *cutting planes*. Esse método consiste na adição de restrições fortemente válidas para reformular o problema e, com isto, diminuir o *range* de soluções. Após essa diminuição, o algoritmo de *branch and bound* é aplicado para resolver de vez o problema. Além disso, algoritmos de planos de corte, combinados com outros algoritmos, estão gerando resultados

promissores para a solução de modelos de programação (KARIMI *et al.*, 2003; JANS E DEGREAVE, 2008).

O terceiro algoritmo existente para encontrar a resposta exata do problema é chamado de redefinição de variáveis. Ele possui como principal objetivo representar o problema de forma gráfica. Apesar de aumentar o número de variáveis ele ajuda a diminuir o tempo de solução pois promove um relaxamento linear muito mais estreito que no modelo de *branch and bound* tradicional. Assim como no caso dos planos de corte, após esse procedimento, o algoritmo de *branch and bound* é aplicado (KARIMI *et al.*, 2003).

O algoritmo de *branch and bound* pode ser visto sendo utilizado em Shim e Kim (2006), Shim e Kim (2007) e é citado em Haase (1996).

## 2.5.2 Heurísticas

Devido à grande maioria dos problemas serem considerados *NP-hard*<sup>8</sup>, a solução por métodos exatos, apesar de apresentar resultados ótimos, muitas vezes, não é prática ou simplesmente se torna inviável devido a essa característica especial. Por isso, as heurísticas foram desenvolvidas para serem métodos de solução para problemas grandes em que valores próximos ao ótimo são aceitáveis, utilizando, para isso, um menor esforço computacional. Um exemplo disso são as heurísticas gluttonas, como a do vizinho mais próximo. (KATOK E OTT, 2000; LUIZ, 2012; SHIM E KIM, 2006; FOO E TAKEJUJI, 1988; SOX *et al.*; 1999; DREXL E KIMMS, 1997; RODAMMER E JUNIOR, 1988; FLOUDAS E XIAXONIA, 2005; KARIMI *et al.*, 2003; LOBO *et al.*, 2007; SALOMON *et al.*, 1991, BUSCHKHUL *et al.*. 2010, ARAUJO E FUCHIGAMI, 2013; BIERWIRTH E MATTFIELD (1999), GUIMARAES *et al.*, 2015; SHIM E KIM, 2007; ALLAHVERDI *et al.*,2008; TAHAR *et al.*, 2006; LIAW *et al.*,2003)

Para um melhor entendimento sobre heurísticas, existe uma classificação proposta por Buschkuhl *et al.* (2010). Nessa classificação as heurísticas são divididas em cinco métodos: heurísticas baseadas em programação matemática, heurísticas lagrangianas, heurísticas baseadas em decomposição e agregação, metaheurísticas, heurísticas do tipo *Greedy*.

O primeiro método de solução da classificação é o das heurísticas baseadas em programação matemática. Essas heurísticas podem ser obtidas a partir dos métodos exatos mas, limitando o tempo de solução desse algoritmos. O resultado encontrado, apesar de não exato,

---

<sup>8</sup> *NP-hard* - *Non-Deterministic Polynomial time* – grupo de problemas difíceis de resolver ocomputacionalmente devido à sua complexidade

pode servir como um bom ponto para iniciar uma solução mais viável. Dentro desse método, podem ser citadas as Heurísticas do tipo *branch and bound*, reformulações no programa, Inequações válidas, Heurísticas do tipo *Fix-and-relax*, Heurísticas de arredondamento e as de Dantzig-Wolf (BUSCHKHUL *et al.*, 2010; GRAVES, 1981).

O segundo método de solução da classificação é o das heurísticas lagrangianas, que podem ser classificadas em dois subtipos, o de relaxamento e o de decomposição. A característica principal dessas heurísticas é de que as restrições complicadas do problema são relaxadas e a sua violação gera uma punição no valor da função objetivo (CARVALHO E NASCIMENTO, 2016; BUSCHKHUL *et al.*, 2010;).

O terceiro método de solução da classificação é o das heurísticas baseadas em decomposição e agregação, das quais podem ser citadas as heurísticas de decomposição baseadas no tempo e de decomposição baseadas no item. A característica principal dessas heurísticas é a de resolver problemas de tamanhos menores e coordenar as soluções individuais. As heurísticas de agregação reduzem os problemas omitindo os detalhes primeiro e apresentando as soluções depois. Já as heurísticas de decomposição quebram o problema em várias partes e criam os programas depois (BUSCHKHUL *et al.*, 2010).

O quarto método de solução da classificação é o das metaheurísticas. Esse método é o mais utilizado para resolver os problemas de forma geral. Esses modelos utilizam conhecimentos específicos para controlar heurísticas já conhecidas visando aumentar a flexibilidade dos modelos, podendo, assim, resolver problemas grandes e complexos. Além disso, esse método geralmente não é determinístico e possui várias soluções não viáveis em seu espaço de solução. As metaheurísticas mais conhecidas são *Simulated Annealing*, Algoritmos genéticos, Heurísticas da colônia de formiga, *Tabu search* e *local search* (MADRONERO *et al.*, 2014).

O quinto método de solução da classificação é o das heurísticas do tipo *Greedy*, que podem ser traduzidas como algoritmos intuitivos. Essas heurísticas, diferentemente das anteriores, trabalham resolvendo período por período a partir de uma solução inicial e possuem o mecanismo que aumenta o tamanho de lote visando reduzir o custo geral.

Os cinco tipos de heurísticas citados podem ser utilizados para resolução dos problemas. Essas heurísticas possuem diferentes características e devem ser aplicadas em diferentes casos. Diferentemente dos métodos de solução exatos, elas não retornam a solução ideal, porém podem ser uma boa saída caso o problema estudado seja muito grande.



### 3 MÉTODO DE PESQUISA

Nesta seção, foi realizada uma análise sobre a classificação do trabalho desenvolvido. Além disso, foi abordado o método de pesquisa utilizado. Essas duas análises foram feitas para demonstrar o modo científico como trabalho foi realizado do ponto de vista metodológico.

#### 3.1 Classificação do trabalho desenvolvido

O trabalho clássico de Bertrand e Fransoo (2002), permitiu padronizar e classificar os trabalhos em engenharia de produção uma forma amplamente aceita pela comunidade acadêmica. Nessa dissertação, a pesquisa é classificada de acordo com quatro pontos, o primeiro, da natureza do trabalho, o segundo, de seus objetivos, o terceiro, da sua abordagem e o quarto, do método.

O primeiro ponto de classificação, com relação à natureza do trabalho, possui duas divisões, a pesquisa básica e a pesquisa aplicada. A primeira delas, a pesquisa básica, busca a evolução da ciência, sem se preocupar com os efeitos práticos por ela gerados. A segunda delas, a pesquisa de natureza aplicada, visa resolver problemas existentes na prática e, geralmente, é ligada a objetivos comerciais (BERTRAND E FRANSOO, 2002).

Observando a classificação de natureza pode se dizer que esse projeto de pesquisa é de natureza aplicada. Isso porque o trabalho não desenvolve novos conceitos, mas sim os utiliza para reduzir os custos de uma indústria. Essa redução de custos ocorre através da diminuição do atraso em peças de um setor através da implantação de uma melhoria no sistema MRP.

A segunda classificação utilizada, denominada do objetivo, pode ser subdividida em quatro tipos: Exploratória, Descritiva, Explicativa e Normativa. A pesquisa do tipo exploratória visa tornar o problema mais fácil de ser compreendido, além de permitir a construção das hipóteses iniciais. A pesquisa do tipo descritiva possui como principal meta encontrar relações entre variáveis e descrever características em determinadas populações ou fenômenos interessantes. A pesquisa explicativa busca determinar os fatores que agem para a ocorrência de determinado fenômeno, podendo este ser físico ou social. O tipo normativo tem como principal interesse o estudo de políticas e estratégias e ações para aperfeiçoar resultados já existentes na literatura, encontrar uma solução ótima ou comparar diferenças nos resultados de várias estratégias. Como a pesquisa atual visa melhorar sistemas já existentes com métodos já

conhecidos na literatura, ela pode ser classificada como normativa (MARTINS *et al.*, 2013; BERTRAND E FRANSOO, 2002).

O terceiro tipo de classificação diz respeito à forma de abordagem do problema, que pode ser quantitativa ou qualitativa. Na abordagem quantitativa são utilizadas informações quantificáveis, ou seja, que podem ser traduzidas em números. Já na abordagem qualitativa, não é possível quantificar essas informações devido à subjetividade da pesquisa. Como a presente pesquisa consegue quantificar todos os dados e variáveis mínimas necessárias ela pode ser considerada como quantitativa (BERTRAND E FRANSOO, 2002).

O quarto e último tipo de classificação diz respeito ao método de pesquisa utilizado. Os métodos são divididos em: experimentos, *survey*, *soft systems methodology*, estudo de caso, pesquisa-ação e modelagem e simulação (BERTRAND; FRANSOO, 2002)

No método de experimentos, as variáveis selecionadas são as que influenciam o fenômeno e após essa seleção são realizados testes controlados para testar uma premissa pré-determinada. A *survey* utiliza a entrevista de pessoas para se explorar melhor um comportamento, podendo este ser físico ou social. A pesquisa-ação ocorre quando a pesquisa envolve partes de problemas que precisam ser resolvidas enquanto a pesquisa ocorre. O *soft systems methodology* visa construir modelos conceituais e compará-los com as atividades no mundo real. O estudo de caso possui como principal objetivo a realização de um estudo de um ou poucos objetos para que um grande detalhamento seja alcançado (BERTRAND E FRANSOO, 2002; MARTINS *et al.*, 2013).

O sexto método, de modelagem e simulação, pode ser empregado quando se é desejável testar um sistema real através de um modelo, testando hipóteses levantadas pelo proponente. Como essa pesquisa testa um sistema sem interferir nele e valida hipóteses para definir possíveis melhorias, ela utiliza o método de modelagem e simulação (BERTRAND; FRANSOO, 2002, MARTINS *et al.*, 2013).

Por fim, a pesquisa atual pode ser classificada como de natureza aplicada, normativa quantitativa e que utiliza como método de pesquisa a modelagem e simulação. Essas três características permitem definir o escopo de pesquisa do trabalho, levando assim a conduzi-la com maior facilidade.

## 3.2 Método utilizado

A modelagem e simulação é um método que tem como principal objetivo experimentar um sistema físico através de um sistema computacional. Por isso, os propósitos principais dele são: conhecer a fundo a operação do sistema e testar novos conceitos antes de colocá-los em prática para não haver perdas. Um sistema pode ser definido como um conjunto de processos que se interagem e possuem uma entrada, um processo e uma saída. Em razão do fato de que o presente trabalho estuda um sistema físico real, já em funcionamento e que não pode ser parado para que se ocorram testes, a definição de modelagem e otimização serve para o caso estudado. Além disso, o que justifica um estudo de simulação é a existência de um problema no mundo real (CHUNG, 2004; SLACK *et al.*, 2009; ROBINSON, 2004).

O uso da simulação também é indicado em modelagens que possuem alta complexidade para se chegar ao valor ideal da função objetivo. Isso acontece em modelos de *lot sizing* devido ao alto número de variáveis envolvidas. Além disso, a simulação apresenta diversas vantagens para modelagens para esse caso em comparação a outros métodos de pesquisa. Essas vantagens são: a experimentação em menor tempo, um menor consumo de recursos que um modelo real, a alta velocidade em se analisar uma grande quantidade de dados e a possibilidade de ser reutilizável para vários casos próximos (CHUNG, 2004).

O método de modelagem e simulação consiste de quatro fases. A primeira fase é a da conceituação. A segunda fase é chamada de modelagem. A terceira fase é chamada de resolução através do programa. Por último, existe a fase de implantação do sistema criado. Essa sistemática pode ser vista na Figura 3-1, que mostra o modelo descrito por Bertrand e Fransoo (2002) adaptado de Mitroff *et al.* (1974).

Ainda segundo Bertrand e Fransoo (2002), o ciclo composto pelas quatro fases nem sempre é completo nos trabalhos acadêmicos. Esses ciclos incompletos ocorrem de acordo com o objetivo da pesquisa. Por exemplo, nos casos em que o objetivo não visa uma solução prática, o modelo é chamado axiomático e não possui a fase de implantação. Para os métodos chamados de empíricos a resolução de problemas reais é a causa de sua existência. Tais problemas podem ser divididos em empíricos descritivos e empíricos normativos. Nos métodos empíricos descritivos a implantação não é necessária. Os empíricos normativos, no entanto, possuem a preocupação de implantar o sistema e resolver o problema. O modelo utilizado nessa dissertação, portanto, é empírico normativo e utiliza as quatro fases do método.

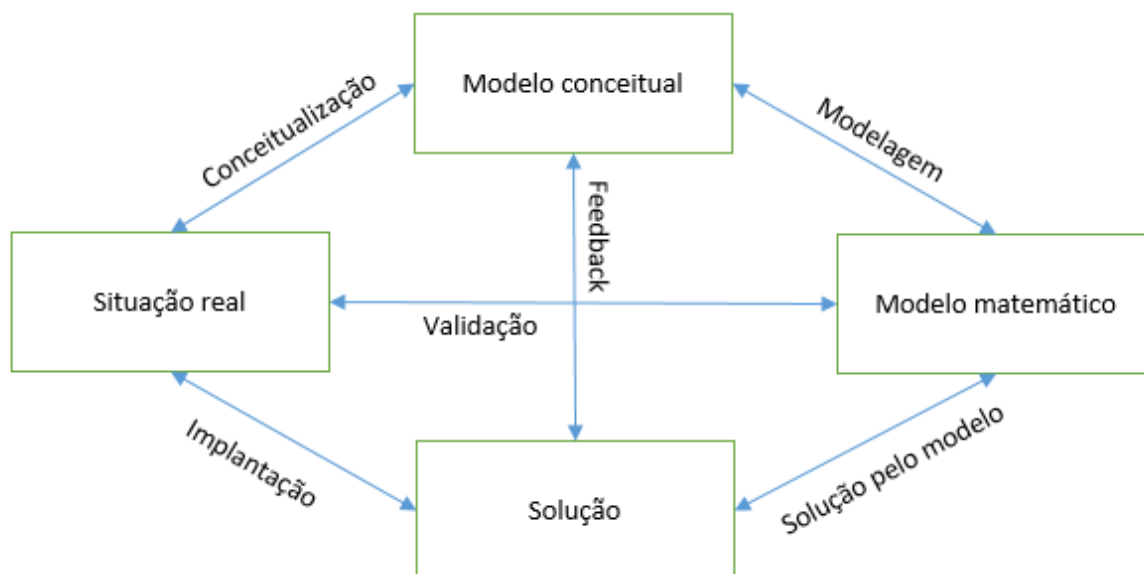


Figura 3.1 - Modelo de Simulação  
Fonte: Mitroff (1974)

Em um problema empírico normativo começa-se, primeiramente, trabalhando com a definição do problema; essa é a primeira fase. Nessa definição, ocorre a criação do esboço do modelo e de suas características. Além disso, são definidas as ferramentas necessárias para o desenvolvimento do mesmo. Tal parte serve, portanto, para criar o modelo teórico a vir ser desenvolvido. Algumas técnicas, como o fluxograma, geralmente são utilizadas visando obter um melhor planejamento da solução, além de ajudar a encontrar possíveis erros de interpretação (BERTRAND; FRANSOO, 2002).

A segunda fase serve para transformar os conceitos teóricos em uma visão matemática. Nessa fase é criado o modelo computacional. Na presente dissertação foi utilizado o *software* de programação MATLAB para que o modelo pudesse ser criado. Além disso, para evoluir ao modelo final, foram criados cerca de dez modelos, nos quais alterações foram sendo realizadas a cada passo e conforme necessidade da fábrica.

A terceira parte do estudo de modelagem e simulação consiste em utilizar os dados e o programa para resolver o modelo. Essa parte é considerada como um processo no qual vão sendo alteradas especificações, para que ocorra um aprendizado através dos resultados obtidos com as saídas do modelo. Por isso trata-se de um método iterativo, onde as melhorias vão sendo encontradas com o tempo (ROBINSON, 2004).

Por último, a última e quarta etapa do método consiste na implantação da solução para o mundo real através da utilização de dados reais. A fase de implantação para esse projeto gerou diversas descobertas para o analista em questão. Tais descobertas foram descritas em formato

de dissertação. Um bom relatório de divulgação deve conter partes básicas que são: um resumo do modelo, os objetivos e os resultados atingidos, além de uma possível lista de recomendações (ROBINSON, 2004).

Portanto, para esse trabalho, foi utilizado o método de modelagem e simulação, do tipo empírico normativo. Para realizar os estudos foi utilizado o *software* Matlab. Para a divulgação das descobertas e dos resultados foi utilizada a presente dissertação.

## 4 MODELO E DADOS UTILIZADOS

Nesta seção, primeiramente, o modelo de *lot sizing* e suas equações foram descritos por completo. Após, foi realizada uma análise sobre as três séries de dados utilizadas, com alta, média e baixa demanda e de outros inputs necessários para realização dos testes. Por último, foi descrito o método para solucionar o problema pelo modelo.

### 4.1 Formulação do problema

Para conseguir testar o programa computacionalmente, primeiro foi necessário modelá-lo matematicamente. Como os tempos de produção variam a partir do tipo do produto e de sua dimensão foram criados índices para representar essas variações. Primeiramente foi criado o índice  $i$ , que determina o tipo do produto a ser fabricado. Em segundo lugar foi criado o índice  $k$ , que determina a dimensão do produto. O terceiro índice criado foi índice  $j$ , que determina o período de fabricação da peça.

A função objetivo do modelo pode ser vista na Equação (4.1). Ela representa a somatória dos atrasos de todas as peças, de todas as dimensões, em todos os períodos analisados.

$$\text{Min } \sum_{i=1}^P \sum_{j=1}^T \sum_{k=1}^D Z_{i,j,k} \begin{cases} i = 1, 2 \dots, P \\ j = 1, 2 \dots, T \\ k = 1, 2 \dots, D \end{cases} \quad (4.1)$$

O próximo passo foi criar as restrições para melhor representar o problema. Um resumo das restrições pode ser visto a seguir. A descrição detalhada de cada uma delas pode ser vista nos próximos parágrafos. A primeira restrição criada foi a da equação de balanço. A segunda restrição criada define a capacidade máxima de produção para o sistema. A terceira restrição criada demonstra se houve ou não funcionamento da máquina naquele período. A quarta restrição criada visa representar a ocorrência ou não de setup. As últimas duas restrições definem os limites das variáveis. As restrições são responsáveis por definir os limites do modelo e torná-lo o mais próximo da realidade estudada.

A primeira restrição criada, a Equação (4.2) original de balanço para a produção, funciona igualmente às suas variantes encontradas em outros ramos da engenharia, como, por exemplo, para o balanceamento de massa na física. Essa equação pode ser descrita como sendo

a soma do estoque inicial, representado por  $S_{j-1}$ , mais a produção atual, representada por  $X$ , menos a demanda do período, representada por  $D$ , que gera o estoque final  $S_{j-1}$ . Todas as variáveis são contadas em peças.

$$-x_{i,j,k} + s_{i,j,k} - s_{i,j-1,k} - z_{i,j,k} + z_{i,j-1,k} = -d_{i,j,k} \quad \begin{cases} i = 1,2 \dots, P \\ j = 1,2 \dots, T \\ k = 1,2 \dots D \end{cases} \quad (4.2)$$

Para atender a presente modelagem, essa equação foi alterada. Foram criadas as folgas do sistema, representadas por  $z$ . Essas folgas dão a flexibilidade para o sistema terminar ordens perto do fim, mesmo que ultrapasse o fim do turno, contando como se fossem do turno que começou. Essa prática é considerada padrão na empresa analisada. A equação de balanço de massa com as modificações de folga no sistema pode ser vista em duas diferentes formas, representadas nas Equações (4.2) e (4.3). Tais variáveis também são contadas em peças

Na Equação (4.2), a demanda é representada exatamente como ocorre na programação, sendo a diferença entre a demanda atual menos produção do período, o estoque inicial existente e folga restante.

$$s_{i,j,k} + z_{i,j-1,k} = -d_{i,j,k} + x_{i,j,k} + s_{i,j-1,k} + z_{i,j,k} \quad \begin{cases} i = 1,2 \dots, P \\ j = 1,2 \dots, T \\ k = 1,2 \dots D \end{cases} \quad (4.3)$$

A Equação (4.3) mostra o estoque final é isolado, ou seja,  $s_{i,j,k}$ , de forma a tornar a equação mais compreensível do ponto de vista produtivo. Nessa equação, o estoque final nada mais é que a soma do estoque inicial somando à produção do período, menos a demanda do mesmo período, além das respectivas folgas no começo e no fim do período.

A segunda restrição pode ser observada na Equação (4.4). Ela modela o sistema quanto à sua capacidade finita, ou seja,  $C$ . A capacidade  $C$  não pode ser menor que a soma dos tempos de produção, representados por  $\sum_i \sum_k t_{prod_{i,k}} * x_{i,j,k}$ , mais a soma dos tempos de setup  $\sum_k t_{setup_k} * h_k$ . Os valores de  $w$  são sobras ou falta de capacidade advindas de um período anterior e que são repassadas para o período atual. Todos os valores são computados em minutos no programa.

$$\sum_{i=1}^P \sum_{k=1}^D t_{prod_{i,k}} * x_{i,j,k} + \sum_{k=1}^D t_{setup_k} * h_k + w_j - w_{j-1} = C \quad \{j = 1, 2, \dots, T\} \quad (4.4)$$

A terceira Equação de restrição, vista em (4.5), modela o funcionamento máquina e demonstra se houve produção para determinado produto. A produção em número de peças de cada tipo é representada por  $x_{i,j,k}$ , enquanto que  $y_{i,j,k}$  é uma variável binária que representa se houve ou não a operação. A constante  $M$  é um valor alto utilizado para tornar a equação possível, pois o resultado da equação deve ser menor ou igual a zero. Essa equação também serve de base para a Equação (4.6).

$$\left( x_{i,j,k} - M * y_{i,j,k} \leq 0 \begin{cases} i = 1, 2, \dots, P \\ j = 1, 2, \dots, T \\ k = 1, 2, \dots, D \end{cases} \right) \quad (4.5)$$

A quarta Equação de restrição serve para determinar se houve o *setup* de determinada dimensão em um determinado período. Se o valor de  $h$  for igual ou maior que 1 significa que houve *setup*, porém se o  $h$  for igual a zero significa que não houve *setup*. O valor de  $n$  mostra o número de produtos analisados no problema. Assim como na Equação (4.5),  $y_{i,j,k}$  representa se houve ou não produção do item. A equação reduzida pode ser vista em (4.6), ou na sua forma dividida em duas equações em (4.7). Na (4.7), caso as duas equações sejam verdadeiras é sinal que houve *setup*.

$$0 \leq - \sum_{i=1}^P y_{i,j,k} + n_{j,k} * h_{j,k} \leq n_{j,k} - 1 \begin{cases} j = 1, 2, \dots, T \\ k = 1, 2, \dots, D \end{cases} \quad (4.6)$$

$$\begin{cases} n_{j,k} * h_{j,k} - \sum_{i=1}^P y_{i,j,k} < n_{j,k} - 1 \\ -n_{j,k} * h_{j,k} + \sum_{i=1}^P y_{i,j,k} < 0 \end{cases} \quad (4.7)$$



Por último, existem as equações de restrições de variáveis, que determinam os limites de cada uma delas. Essas restrições podem ser vistas na Equação (4.8) e (4.9).

$$x, s, z, w, C, n \geq 0 \quad (4.8)$$

Como comentado nas Equações de restrição (4.5) e (4.6), a variável  $y$  é uma variável binária.

$$y \in \{0,1\} \quad (4.9)$$

O modelo conceitual completo pode ser observado nas Equações 4.1 até 4.9.

$$\text{Min Min } \sum_{i=1}^{13} \sum_{j=1}^7 \sum_{k=1}^5 Z_{i,j,k} \quad (4.1)$$

$$\text{S.A. } -x_{i,j,k} + s_{i,j,k} - s_{i,j-1,k} - z_{i,j,k} + z_{i,j-1,k} = -d_{i,j,k} \quad \begin{cases} i = 1,2 \dots, P \\ j = 1,2 \dots, T \\ k = 1,2 \dots D \end{cases} \quad (4.2)$$

$$\sum_{i=1}^P \sum_{k=1}^D t_{prod_{i,k}} * x_{i,j,k} + \sum_{k=1}^D t_{setup_k} * h_k + w_j - w_{j-1} = C \quad \{j = 1,2, \dots, T\} \quad (4.4)$$

$$x_{i,j,k} - M * y_{i,j,k} \leq 0 \quad \begin{cases} i = 1,2 \dots, P \\ j = 1,2 \dots, T \\ k = 1,2 \dots D \end{cases} \quad (4.5)$$

$$0 \leq - \sum_{i=1}^P y_{i,j,k} + n_{j,k} * h_{j,k} \leq n_{j,k} - 1 \quad \begin{cases} j = 1,2, \dots, T \\ k = 1,2, \dots, D \end{cases} \quad (4.6)$$

$$x, s, z, w, C, n \geq 0 \quad (4.8)$$

$$y \in \{0,1\} \quad (4.9)$$

Com o modelo conceitual criado, a pesquisa passou para a fase de modelagem. Nessa fase, o modelo conceitual torna-se um modelo matemático, onde os outros inputs necessários são definidos para que ele possa ser posteriormente resolvido.

## 4.2 Modelagem matemática e solução pelo modelo

Na fase de modelagem matemática, como já visto no capítulo 3, os conceitos teóricos da seção 4.1 são transformados em uma visão matemática. Nessa fase foi criado o modelo computacional, que depende das relações entre as equações e dos dados utilizados.

Os dados utilizados no modelo são descritos juntamente com seus usos nas equações na subseção 4.2. Já na subseção 4.3, o sistema de solução pode ser visto.

### 4.2.1 Dados utilizados

Os dados utilizados na fase de implantação do sistema são dados reais de uma empresa do ramo automobilístico. Esses dados foram divididos em três diferentes séries, uma com alta demanda, uma com média demanda e a última com baixa demanda. A obtenção dessas informações ocorreu através do sistema MRP da empresa estudada.




Figura 4.1 - Licenciamento de veículos no Brasil em 2016

Fonte: ANFAVEA

Tais dados foram coletados em diferentes meses do ano de 2016, para que o modelo construído fosse testado em diferentes casos. Isso porque, conforme é possível observar nas Figuras 4.1 e 4.2, o mercado automobilístico possui grande variação de demanda, mesmo que para curtos períodos de tempo.

A Figura 4.2 mostra o número de licenciamentos de carros mês a mês desde 2011 até setembro de 2016.




Figura 4.2 - Licenciamento de automóveis no Brasil desde 2011  
Fonte: ANFAVEA

Na Figura 4.2, a demanda do ano de 2016 já mostra que, dentro de um curto período de tempo, ou seja, sete meses, o número de carros licenciados saiu de 146.809 em fevereiro, para 183.890. A diferença entre esses meses é de 37.081 automóveis, o que, em termos de porcentagem, representa 25% de variação. Essa variação afeta a capacidade das fábricas. O efeito é um aumento do nível de ociosidade das linhas de produção ou alta quantidade de estoques de produtos acabados. Esses efeitos são remetentes da estratégia utilizada por cada organização para gerenciar a sua capacidade produtiva.

Existem três opções para se gerenciar a capacidade de uma fábrica, o nivelamento da produção, o acompanhamento da demanda e o gerenciamento da demanda (Slack et al., 2009). A primeira delas consiste em nivelar a produção, ou seja, produzir sempre a mesma quantidade, mesmo que a demanda esteja baixa. Essa estratégia gera estoques durante a demanda baixa para atender a demanda alta. A segunda estratégia para capacidade consiste no acompanhamento da

demanda, ou seja, variar a capacidade rapidamente através de horas extras ou subcontratação. A terceira estratégia consiste no gerenciamento da demanda. Esse tipo de estratégia é muito mais conhecida para o ramo de serviços e pode ser entendida de forma fácil através da variação de preços realizada por um hotel quando sua demanda está baixa (SLACK *et al.*, 2009).

Esses tipos de estratégias são utilizados em conjunto pelos gestores. Isso porque a produção possui objetivos paradoxais como, por exemplo, redução de custos e estoque, ao mesmo tempo em que o investimento de capital é minimizado. Sem um software de MRP bem estruturado, o impacto na fábrica pode ser diferente do previsto.

Como o modelo criado deve trabalhar nos mais diferentes tipos de demanda, dados de três períodos com demandas bem diferentes foram utilizados para o trabalho. Isso se deve em razão de, como mostrado na Figura 4.1, o mercado automobilístico possui uma variação muito grande de pedidos em curtos períodos de tempo. Além disso, mesmo que somente para a indústria automobilística, podem haver estratégias diferentes de produção de mês para outro, e um modelo de *lot sizing* deve ser robusto o suficiente para responder a essas rápidas mudanças.

Outros dados, como os estoques iniciais, também foram definidos, para que se possa resolver o modelo.

#### **4.2.1.1 Introdução sobre os dados analisados**

Essa introdução possui como objetivo analisar a demanda completa dos produtos fabricados pela empresa em uma de suas operações e os dados utilizados para criar o modelo matemático. Na operação estudada, apenas as características significativas para a execução do *setup* e o tempo de fabricação foram consideradas, o que gerou um *input* de 13 produtos no total.

Esses produtos foram divididos em treze tipos diferentes na característica G e D. A característica D varia do 1 ao 7, e interfere no *setup* da máquina, como pode ser visto na terceira coluna da Tabela 4.1. O *setup* pode ser relacionado ao diâmetro da peça, circunferência ou sua altura. A linha da peça, a característica G, varia de 0 ao 3, e pode ser utilizada caso as operações posteriores a estudada se dividam. Isso quer dizer que se a característica G for utilizada na modelagem as linhas devem ser abastecidas individualmente, sendo necessário um balanceamento de produção dos tipos de produtos de 0 a 3 durante os períodos para que nenhuma dessas linhas fique sem peças. Para os testes realizados no capítulo 5 não foi utilizada

essa característica. Ainda, como pode ser observado na Tabela 4.1, alguns itens, apesar de possuírem tempos iguais de fabricação, possuem *setup*, outros, no entanto, não realizam *setup*, mas possuem tempos diferentes de fabricação.

Esses dados podem ser utilizados na Equação (4.1), onde  $i$  representa o tipo de produtos, e pode ir até 13. O índice  $j$ , representando o *setup*, vai de 1 a 7. O índice  $k$ , vai determina o período de fabricação é vai de 1 a 5.

Tabela 4.1 - Variação dos produtos de acordo com G e D

Nome do produto	G	D	Tempo de Produção (min)
1	0	3	0,0271
2	1	6	0,243
3	1	7	0,46
4	2	1	0,318
5	2	2	0,0195
6	2	3	0,0218
7	2	4	0,0258
8	2	5	0,0272
9	3	1	0,0318
10	3	2	0,0195
11	3	3	0,0218
12	3	4	0,0246
13	3	5	0,0348

$$\text{Min } \sum_{i=1}^{13} \sum_{j=1}^7 \sum_{k=1}^5 Z_{i,j,k} \quad (4.1)$$

A parte relativa aos estoques pode ser vista na Equação (4.2), que é a equação de balanceamento. No caso dos estoques, é importante lembrar que eles são relativos a cada tipo de produto e tem valor inicial igual a zero, assim como valor final. Esses valores podem ser vistos na Equação (4.10). Os valores para o estoque são contabilizados em peças. No caso dos testes da dissertação o estoque foi considerado para os 13 tipos de peças, não possuindo limites. Porém, caso seja necessário, é possível utilizar como índice a característica P para determinar a qual tecnologia o produto pertence, utilizando, dessa forma, estoque segmentados.

$$s_{i,j,0} = 0 \quad s_{i,j,5} = 0 \quad (4.10)$$

As folgas,  $z$ , possuem comportamento parecido ao dos estoques, e devem começar igual a zero e terminar iguais a zero. Isso porque a capacidade é finita e deve ser igual ao valor determinado na soma dos períodos analisados.

$$z_{i,j,0} = 0 \quad z_{i,j,5} = 0 \quad (4.11)$$

A demanda, representada por  $d$  na Equação (4.2), pode ser vista nas seções 4.2.1.2, 4.2.1.3, 4.2.1.3 e representa o número de peças a serem fabricadas em um período. Um exemplo fácil pode ser visto na Equação (4.13). Nesse caso, a demanda utilizada é para o alto volume de peças. Esse valor também pode ser visto na Tabela 4.2.

$$d_{i,j,k} = 79434 \text{ peças} \quad (4.13)$$

O setup, existente na Equação (4.4), é de 30 minutos e ocorre quando o valor de  $i$  varia dentro de um período. Um exemplo de custo de setup em minutos pode ser visto na Equação (4.14).

$$\sum_k t_{setup_k} = 30 \text{ minutos} \quad (4.14)$$

Os valores de capacidade de cada período, vistos também na Equação (4.2) podem ser observados no capítulo 5, onde ocorrem os testes com o modelo. A capacidade é representada por  $C$ .

A variável  $y$  representa o estado da máquina, ligada ou não, ajudando também no setup. Quando essa variável é acionada significa que houve produção e conseqüentemente setup no turno. O exemplo da Equação (4.14) mostra que houve setup para a peça 12, de característica  $D$  igual a 5, no período 2.

$$\sum_i y_{3,5,2} = 1 \quad (4.14)$$

Essa variável é utilizada nas Equações (4.5) e (4.6). Na Equação (4.6) a letra  $n$  representa o número de produtos analisados, que no caso atual é igual a 13.

Com esses dados, é possível montar o modelo matemático. Porém ainda é necessário avaliar quais são as demandas para que ele fique completo. Essas demandas podem ser vista na subseção 4.2.1.2, 4.2.1.3, 4.2.1.4.

#### 4.2.1.2 Primeira série de dados analisada - demanda alta

A primeira série de dados coletada ocorreu com uma demanda alta de peças. Isso visa contemplar meses como o de agosto de 2016, onde a demanda geralmente é maior. Esse valor elevado de produção pode ser observado na Figura 4.2. A divisão dos produtos e suas demandas durante 5 dias pode ser vista na Tabela 4.2.

Tabela 4.2 - Organização da produção para o caso de demanda alta

		Demanda (peças/dia)				
		1	2	3	4	5
Tipo do produto	1	200	33260	32966	30000	46000
	2	2000	0	0	0	0
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	1235	0	12950	18200	6400
	6	38050	29675	0	12660	3000
	7	0	0	3142	0	5600
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	2200	2109	0	0	5150
	11	0	13560	0	24100	0
	12	20650	8650	0	21000	22150
	13	14000	13600	0	25000	0

Um ponto importante sobre essa demanda é que ela não possui a peça do tipo 3. Essas peças são as que possuem o maior tempo de produção e torna o sistema mais difícil de ser resolvido. Essa variação das peças a serem fabricadas é comum na empresa analisada. É possível observar ainda, que, nas massas de dados para demanda média e baixa, os tipos de peças fabricadas variam. A média de produção por dia com esses dados chega a 89.721 peças por dia. O total de peças a serem produzidas no período é igual a 448.406.

Com essa massa de dados é possível analisar, portanto, se o modelo criado se comporta bem quando ocorre um grande volume de produção. Além disso, a maioria das peças que

possuindo um tempo de fabricação baixo, diferentemente dos próximos tipos de demanda a serem apresentados.

#### 4.2.1.3 Segunda série de dados analisada - demanda média

A segunda série de dados coletada ocorreu com uma demanda média de peças. Isso visa contemplar os meses como o de maio de 2016, onde a demanda geralmente é média. Esse volume de produção na produção pode ser observada na Figura 4.2. A divisão dos produtos e suas demandas durante 5 dias pode ser vista na Tabela 4.3.

Tabela 4.3 - Organização da produção para o caso de média demanda

		Demanda (peças/dia)				
		1	2	3	4	5
Tipo do produto	1	8600	8600	34400	0	0
	2	0	1400	0	4500	5800
	3	850	0	0	0	0
	4	2160	0	0	0	0
	5	12100	0	0	2600	0
	6	25876	23438	26413	39351	27000
	7	0	4070	1150	0	3502
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	24260	28600	3000
	12	3225	12000	14150	17300	0
	13	12500	0	12500	0	12500

Nesse conjunto de dados é possível observar que, diferentemente dos dados da alta demanda, existe a produção das peças do tipo 2 e 3. Essa produção altera consideravelmente o tempo de fabricação total e isso pode tornar os dois modelos parecidos em termos de tempo, apesar da diferença numérica. Nesse caso, a produção diária chega a 74.588 peças por dia, totalizando 372.944 em 5 dias. A variação de tipos de peças fabricadas é alta, pois essa série contém produtos de todas as características analisadas, P, que podem ser observadas com ajuda da Tabela 4.1. Isso indica um *mix*<sup>9</sup> maior de produtos, o que pode afetar o número total de setups.

<sup>9</sup> Mix – Número de tipos de produtos a serem fabricados em determinado período (SLACK *et al.*, 2009).



Outro ponto importante dessa massa de dados é que somente ela contém a peça 3, o que a torna especial. Isso se dá em decorrência de essa peça possuir um tempo de produção muito discrepante se comparado a outros produtos fabricados, como pode ser visto na Tabela 4.1.

Com essa massa de dados é possível analisar, portanto, se o modelo criado se comporta bem quando ocorre um médio volume de produção com peças que possuem um *mix* variado de produtos.

#### 4.2.1.4 Terceira série de dados analisada - demanda baixa

A terceira série de dados coletada ocorreu com uma demanda baixa de peças. Isso visa contemplar os demais meses com fevereiro de 2016. Essa baixa na produção pode ser observada na Figura 4.2. A divisão dos produtos e suas demandas durante 5 dias pode ser vista na Tabela 4.4.

Tabela 4.4 - Organização da produção para o caso de demanda baixa

		Demanda (dias)				
		1	2	3	4	5
Tipo do produto	1	27480	8600	8600	16500	17200
	2	1853	740	4100	0	1190
	3	0	0	0	0	0
	4	6800	0	0	0	0
	5	0	0	0	0	0
	6	1000	12938	14038	0	14700
	7	0	0	0	1150	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	600	0	0	0	0
	12	8650	10950	38500	8650	0
	13	0	0	0	25920	12960

Nesse conjunto de dados, para a demanda baixa, é possível observar que vários tipos de peças não são fabricados. Os tipos que são fabricados são os tipos mais vendidos, como, por exemplo, o tipo 1 e 12. Apesar da demanda estar baixa, o produto do tipo 2 é fabricado, o que retrata bem a inconstância dos pedidos nesse tipo de indústria. Além disso, demandas baixas no

mercado automobilístico podem ocorrer devido a diversos fatores, desde aumentos de impostos até crises gerais na economia.

Com esse conjunto de dados é possível observar, portanto, o comportamento do modelo para casos onde a demanda é baixa e não existem muitos tipos de produtos a serem fabricados. Mesmo assim alguns produtos que possuem alto tempo de fabricação são produzidos. Essa variação visa analisar possíveis problemas no modelo desenhado.

## 4.2.2 Solução pelo modelo

### 4.2.2.1 Etapa de aquisição dos dados

A aquisição dos dados apresentados na subseção 4.2.1 foi realizada através da importação do banco de dados da empresa existente no SAP.

Esse banco de dados possui os dados relativos ao setup, os tempos de produção, as quantidades de peças a serem realizadas por dia e o tipo de cada peça. Além disso, as tecnologias de cada produto também podem ser verificadas.

A importação dos dados ocorre no formato bruto. Dessa maneira, foi necessário realizar a criação de uma tabela de *excel* para tratar os dados e enviá-los ao *MATLAB*.

Tabela 4.5 - Planilha excel com os dados prontos para importação para o Matlab

Q	P	T	D
1.235	2	1	2
1.500	3	1	5
13.475	2	1	3
13.475	2	1	3
2.200	3	1	2
12.000	3	1	4
1.099	2	1	5

A tabela em *excel* conta com três abas. A primeira aba recebe os dados brutos, a segunda aba trata os dados e os deixa em forma organizada para o *MATLAB*. A terceira planilha simula os dados conforme a programação atual da fábrica.

```

%% -----Importa demanda do experimento v5excel-----%
filename = 'Dados_planejamento_de_experimentosv5.xlsm';
Dados_sap_RTLB = xlsread(filename,'Import_matlab');
dem = Dados_sap_RTLB;
%-----%

```

Figura 4.3 Código de importação do MATLAB

Dentro do código do modelo no *MATLAB* existe um link para que seja possível a importação direta da planilha e que seja economizado tempo para testar o modelo. Esse código pode ser visto na Figura 4.3.

O fluxograma da etapa de aquisição de dados pode ser visto na Figura 4.4.

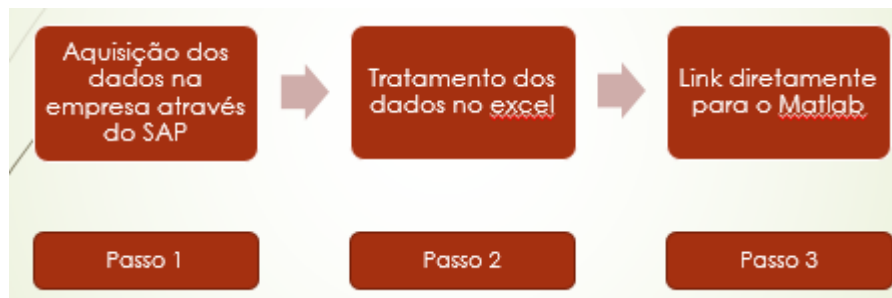


Figura 4.4 - Fluxograma para aquisição dos dados para o modelo.

Com essas etapas preenchidas, somente é necessário executar o modelo. O método de execução do modelo pode ser visto em 4.2.2.2.

#### 4.2.2.2 Etapa de execução do modelo

A etapa de execução do modelo consistiu de quatro passos. Sendo eles: transferência e criação de variáveis, criação de tabelas necessárias para o modelo, realização da otimização, obtenção dos resultados.

O primeiro passo, transferência e criação de variáveis, diz respeito à criação de constantes como tempo de setup e vetores como o número de minutos por peça. Alguns vetores do problema podem ser vistos na Figura 4.5

custo_producao	13x1 double
custo_setup	13x1 double
Dados_produtos	13x3 double
Dados_sap_RTLB	35x4 double
dem	13x5 double

Figura 4.5 - Vetores no Matlab

O segundo passo, criação das tabelas necessárias, pode ser entendido como o desenvolvimento das tabelas para que a otimização seja realizada. As tabelas podem ser extraídas da formulação presente na Figura 4.6. Por exemplo, o vetor  $b$  e a tabela  $A$ .

$$\begin{aligned} \min (\text{ou max}) \quad & c^t x \\ \text{sujeito a :} \quad & Ax = b \\ & x \in \mathbb{R}_+^n \end{aligned}$$

Figura 4.6 - Tabelas a serem feitas na P.O.

O terceiro passo foi a realização da otimização através de uma função pré-definida chamada de *intlinprog*. Essa função é responsável por resolver problemas inteiros dentro do MATLAB. Como o trabalho não focou no método de resolução, foi utilizado o já existente.

O quarto passo foi a obtenção dos resultados, nessa fase os resultados podem ser vistos após a otimização. Os resultados saem na forma de vetores ou constantes e são tratados para forma gráfica para melhor entendimento. O tramento dos resultados pode ser visto no capítulo 5.

O fluxograma na Figura 4.7 descreve os processos para execução do modelo.

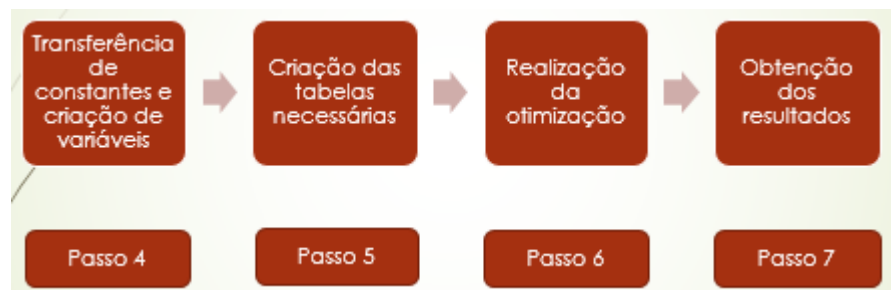


Figura 4.7 - Fluxograma de execução do modelo

Com as duas etapas, aquisição dos dados e execução do modelo, é possível partir para os resultados encontrados com os dados apresentados na subseção 4.2.1.

## 5 RESULTADOS

Na capítulo de número 5, foi realizada uma análise dos resultados obtidos ao se executar o modelo a partir dos dados do capítulo 4. Os resultados estão divididos entre demanda alta média e baixa. Os resultados dos testes com essas três séries são apresentados em forma gráfica e tabelada, com breve discussão dos pontos importantes encontrados. Em cada caso, os resultados especiais gerados pela execução são tratados observando a sua causa na modelagem criada. Ao final das análises, são apresentadas três tabelas contendo o resumo e comparação dos casos analisados, observando a redução do atraso em número de peças e os resultados financeiros obtidos.

### 5.1 Análise de demanda alta

Os dados utilizados para simular uma demanda alta possuem uma necessidade total de produção de 448605 peças para os cinco dias. Dividindo-se esse valor por cinco, encontra-se o valor diário de 89.721 peças/dia. Nos casos de demanda média e baixa, os valores diários de produção são inferiores, sendo de 74.588 e 48.623 peças/dia, respectivamente. Antes de testar o modelo criado, foram demonstrados os métodos atuais utilizados pela empresa para programar o setor estudado, o da retificação.

Após, o modelo de *lot sizing* criado foi testado, visando comparar os resultados com o modelos utilizados atualmente pela fábrica. Além disso, o conjunto de dados de um ambiente de produção elevada visa verificar se esse modelo criado funciona bem nessas condições extremas. Deste modo, três situações nesse modelo foram testadas para esse tipo de demanda.

A primeira variação considera o custo de atraso por tipo de peças iguais a 1 e os custos de atraso por dia também iguais a 1. A segunda variação altera os custos de atraso das peças do tipo 2 e 3 para 7, pois elas possuem elevados tempos de fabricação e geram efeitos adversos na programação. A terceira variação mantém os custos da peças 2 e 3 diferentes dos outros e altera o custo do atraso por dia. Assim, o custo do atraso em dias sai de 1, no primeiro dia, para 5, no quinto dia. Esse modelo visa retardar os atrasos com mais de dois dias na fabricação. Os resultados dos três modelos são tabelados ao fim da seção para que seus resultados possam ser comparados de forma mais prática.

O conjunto de dados testado nessa subseção pode ser visto na Tabela 5.1, sendo dividido entre os períodos de necessidade no eixo  $x$  e entre as famílias dos produtos existentes no eixo  $y$ .

Tabela 5.1 - Demanda alta dos produtos dividida em períodos e famílias

		Demanda (peças/dia)				
		1	2	3	4	5
Tipo do produto	1	200	33260	32966	30000	46000
	2	2000	0	0	0	0
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	1235	0	12950	18200	6400
	6	38050	29675	0	12660	3000
	7	0	0	3142	0	5600
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	2200	2109	0	0	5150
	11	0	13560	0	24100	0
	12	20650	8650	0	21000	22150
	13	14000	13600	0	25000	0

A partir dos dados obtidos da Tabela 5.1, o planejamento utilizado atualmente consiste em multiplicar o número de lotes vezes o tempo de fabricação de cada peça e considerar todos os *setups* como existentes. Esse planejamento configura uma demanda de tempo bem maior do que se houvesse alguma otimização. Os tamanhos dos lotes podem ser vistos no anexo 1. Nesse caso, ou seja, 89.271 peças por dia, existem 62 lotes a serem fabricados em cinco dias, o tempo total de fabricação incluindo o *setup* seria de 13.653 minutos. Esse valor, traduzido em horas, equivale a 45,5 horas por dia de máquinas e mão de obra direta. A capacidade do setor pode exceder 24 horas por dia pois existe mais de uma máquina para o setor, apesar de o algoritmo ser *single machine*. Os valores para esse tipo de programação podem ser vistos na Tabela 5.2.

Apesar dessa grande capacidade, ainda haveria atrasos na produção de 745 minutos no dia 4, o que, convertido em peças, resultaria em média de 28.076 unidades, como pode ser visto na tabela 5.2. Para chegar ao número de 28.076 peças, foi utilizada a regra de proporcionalidade, que é apresentada a seguir, na qual  $(x-130960)$  é o atraso considerado. Nesse caso foi encontrado o atraso relativo ao quarto dia.

Tabela 5.2 - Dados de produção para o modelo de alta demanda contando todos os setups

Demanda dia						
Dia	1	2	3	4	5	Total fim
Peças	79434	100854	49058	130960	88300	448606
Minutos	2413	2571	1227	3356	2227	11793
Setup qts	13	12	9	15	13	0
Setup mins	390	360	270	450	390	1860
Total dia min	2562,98	2691,06	1316,97	3475,87	2316,6	12363,47
Capacidade	2730	2730	2730	2730	2730	13650
Atraso	0	0	0	745	0	745

Porém, existe um outro modo de se observar a produção, que considera apenas o dia e o número de *setups*, aproveitando os *setups* que ocorrem dentro do dia. Esse modelo tem a característica principal de não ser capacitado, ou seja, pode vir a gerar atrasos desnecessários e bolhas na produção. Ele pode ser considerado como próximo ao CLSP, porém realizando uma otimização manual. Nesse caso, o tempo total consumido é de 12350 minutos, que, traduzidos em números de hora, chegam a 41,1 horas de trabalho por dia. Comparando-se com o modelo anterior, é possível computar o ganho de cerca de 4 horas de produção a partir do modelo inicial, além da diminuição do total de minutos consumidos de parte da mão de obra direta. Esses dados podem ser vistos na Tabela 5.3.

Tabela 5.3 - Modelo de programação atual da fábrica considerando aproveitamento de setups

Demanda dia						
Dia	1	2	3	4	5	Total fim
Peças	79434	100854	49058	130960	88300	448606
Minutos	2413	2571	1227	3356	2227	11793
Setup qts	5	4	3	4	3	19
Setup min	150	120	90	120	90	570
Total dia min	2563	2691	1317	3476	2317	12363
Capacidade	2470	2470	2470	2470	2470	12350
Atraso	93	221	0	1006	0	1320

Nesse tipo de modelagem, o atraso estimado médio seria de aproximadamente 1320 minutos, desigualmente distribuídos entre os dias, porém o atraso em peças seria de 49066, muito maior que o modelo anterior. Ao analisar a demanda de acordo com o proposto por esse método, foi possível observar que o tempo de fabricação estava variando de um dia para o outro,

gerando atrasos desnecessários. Por exemplo, no dia 4, a demanda em minutos é de 3476, enquanto que, no dia 3, a demanda é de 1317 minutos; a diferença entre esses dois dias é de 2159 minutos. Essas variações impactam diretamente na eficiência da programação, trazendo uma ineficiência para o sistema.

A variação na demanda pode ser vista na Figura 5.1, na qual a linha laranja mostra a capacidade disponível em minutos, enquanto que a linha azul refere-se à demanda dia-a-dia. Outra informação importante diz respeito ao eixo  $x$  do gráfico, que mostra a evolução do tempo em dias.

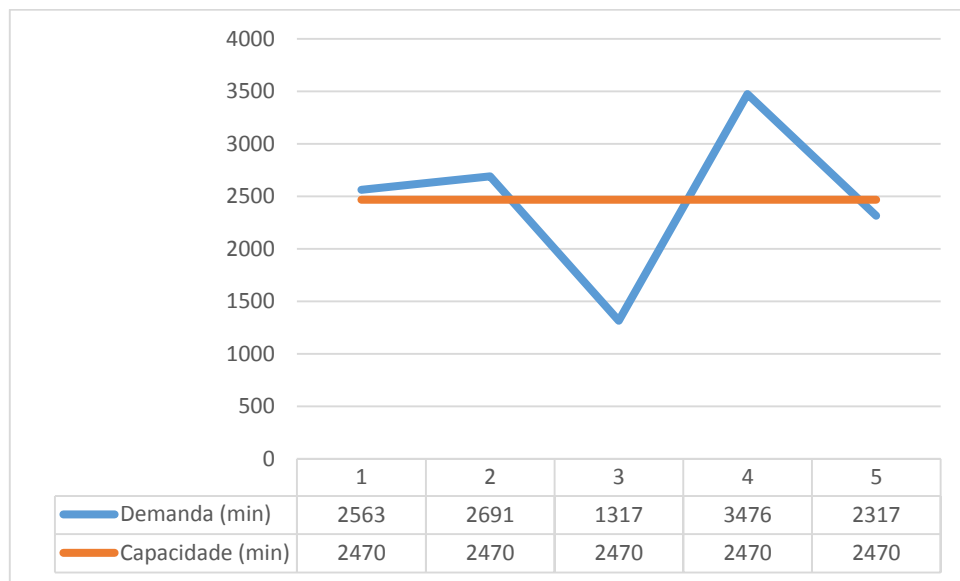


Figura 5.1 - Comparação de demanda x capacidade para demanda alta.

Ao observar o gráfico, é possível notar que, caso a demanda fosse seguida dia-a-dia, a produção não seria atendida. Isso porque, como a produção do quarto dia é muito maior que a capacidade, ela não conseguiria ser absorvida no quinto dia. O efeito desse atraso seria a entrega prejudicada para o cliente ou até mesmo a não entrega.

Esse problema procurou ser sanado pelo modelo desenvolvido, por isso, foi adicionada ao algoritmo a equação de restrição de capacidade que pode ser vista na Equação (5.1). Ela restringe a somatória dos *setups* mais o tempo de fabricação ao tempo disponível por período,  $C$ . Além dos tempos de *setup*, existem as folgas de outros períodos, que podem adicionar capacidade ao período atual. Essas folgas são representadas por  $w$ .

$$\sum_i \sum_k t_{prod_{i,k}} * x_{i,j,k} + \sum_k t_{setup_k} * h_k + w_j - w_{j-1} = C \quad \{j = 1, 2, \dots, T\} \quad (5.1)$$



Para se testar o modelo, foi definida uma capacidade maior que o necessário, pois, com isso, o modelo não seria encerrado por problemas na restrição da Equação (5.1), sendo de 2560 minutos por dia, ou seja, 12800 minutos para os 5 dias. O primeiro teste realizado com os dados para a demanda alta e com o modelo criado considerou os pesos dos atrasos dos produtos como sendo iguais para todos. Além disso, os produtos poderiam ser fabricados todos os dias caso fosse necessário. A equação dos custos dos atrasos para produtos pode ser observada em (5.2).

$$\text{Custo atraso peça} = [1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1] \quad (5.2)$$

O teste realizado foi bem sucedido e os períodos de fabricação de cada peça podem ser vistos na Tabela 5.4. Essa tabela mostra que todas as peças necessárias foram fabricadas, não havendo problemas na capacidade. Algumas peças avulsas aparecem no modelo pois estão dentro do erro tolerado. Esse erro é de  $1 \times 10^{-3}$ .

Tabela 5.4 - Valores de produção por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	9703	23757	62966	0	46000
	2	0	1695	305	0	2
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	1235	0	12950	24596	4
	6	38050	29675	0	15660	0
	7	0	0	3142	0	5600
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	4309	0	0	0	5150
	11	0	13560	0	24100	0
	12	29299	4	13208	7789	22154
	13	14046	13554	0	25000	27

Com a produção inteiramente entregue, foi possível verificar quais itens ficaram atrasados e por quantos períodos. Além disso, é possível observar também qual foi o total de peças atrasadas por tipo e comparar com os métodos atualmente utilizados pela empresa em questão. Essa verificação pode ser feita através da Tabela 5.5.

Tabela 5.5 - Atraso em cada período por tipo de produto

		Atraso(peças)				
		1	2	3	4	5
Tipo do produto	1	0	0	0	0	0
	2	2000	305	0	0	0
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	0	0	0	0	0
	6	0	0	0	0	0
	7	0	0	0	0	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	0	0	0
	12	0	0	0	0	0
	13	0	0	0	0	0

O atraso ocorre somente no produto do tipo 2, durante dois períodos, e tem o valor total de 2305 peças, que pode ser traduzido em 1145 minutos em tempo. Outro ponto importante que pode ser avaliado é que o montante total de 2305 peças foi dividido em duas partes, sendo necessário, portanto, a realização de dois *setups*. Esse atraso na peça do tipo 2 ocorre pois ela possui o maior tempo de fabricação das peças produzidas no período. Como o sistema visa reduzir o número de peças atrasadas, ele opta por deixar de fabricar as com maior tempo de produção. Essa diferença dos tempos de produção é grande, sendo que o produto 1 possui tempo de produção de 0,0271 minuto, enquanto que a do tipo 2 é de 0,2430 minuto. Portanto, a peça 2 é quase 9 vezes mais lenta de produzir que a peça 1.

Ao se comparar o número de peças atrasadas do modelo original com o modelo proposto é possível relatar grande melhora. No modelo original o atraso é de 28076 peças, enquanto que no modelo otimizado ele é de 2305 peças, que, traduzido em termos percentuais, representa uma melhora de 91%.

Outra análise importante a se fazer é verificar se a produção ficou nivelada, isto é, apresentando valores de demanda versus capacidade plausíveis entre os períodos. Para isso foi criado um gráfico com os valores de produção mais *setup* de cada período e sua capacidade. Esse gráfico pode ser visto na Figura 5.2.




Figura 5.2 - Utilização do modelo de otimização com custos iguais a 1.

A partir da análise da Figura 5.2 é possível observar que a produção dos itens possui uma tendência mais linear que no da Figura 5.1. Isso torna a programação realizada pelo modelo muito mais tangível em termos práticos, além de diminuir os atrasos.

Outro ponto importante a ser abordado diz respeito às diferenças entre a capacidade estimada dia e a utilizada. Isso acontece devido ao fato do modelo possuir a programação de folgas e atrasos na produção. Essas folgas podem ser observadas na Equação (5.1) e são representadas por  $z$ . Portanto, os minutos a mais observados no dia 1, 2 e 3 são repassados de forma contínua para o quarto dia como se houvesse um empréstimo. Essa característica ocorre na sua forma prática para que o fim da operação de algum lote de produtos não seja interrompido pela falta de alguns minutos no fim do período. Essa alteração não compromete a capacidade final do modelo. Além disso, a folga foi programada para evitar a perda de tempo nos fins dos períodos, problema recorrente nos modelos CLSP tradicionais e que os torna não condizentes com a realidade estudada.

Ao se fazer uma análise prática do tempo de produção desse modelo em comparação com o primeiro, é possível verificar que houve uma redução significativa de minutos utilizados. Esses minutos configuram uma melhora no tempo de *setup*. O tempo total de produção é de 12800 minutos para o modelo testado enquanto que, no modelo utilizado pela empresa, é de 13650. A diferença é de 850 minutos, ou seja, quase um terço de um dia de melhora. Essa diferença, em termos percentuais, é de 6,2%, o que representa uma melhora de produtividade difícil de conseguir na maioria das empresas, como pode ser visto na Figura 5.3. Essa figura

mostra a evolução da taxa de produtividade no trabalho da indústria nos anos anteriores. Além disso, dos 12800 minutos programados, somente 12575 são utilizados, ocorrendo uma sobra de 225 minutos. Esses minutos poderiam ser utilizados para se fabricar mais peças ou para a realização de outras tarefas, como por exemplo, limpeza de maquinário.




Figura 5.3 - Evolução da produtividade no trabalho  
Fonte: CNI

Traduzindo essa melhora de tempo em termos financeiros, pode-se somar a hora homem com a hora máquina economizada. Além disso, a redução na necessidade do frete aéreo também pode ser calculada. Os dados usados para essa estimativa foram coletados com a empresa em questão. Para o caso de hora-máquina o custo é de R\$ 20,00, já o custo de homem-hora é de R\$ 17,96.

No caso dos fretes aéreos, segundo a empresa, eles são 4 vezes mais caros que os fretes marítimos, popularmente mais utilizados devido a sua confiabilidade e preço. Além disso, o custo do frete aéreo por peça é de 0,16 centavos maior se comparado com o marítimo. De forma prática, quando ocorre um atraso e o pedido é urgente a empresa paga 0,16 centavos a mais por peça produzida. Como, nesse caso, os números de produção são altos, o custo dos fretes aéreos os tornam proibitivos para serem utilizados com frequência, o que justifica mais uma vez o estudo do modelo. No entanto, nem todos os itens atrasados são enviados de forma aérea, por isso, foram realizadas duas estimativas do custo total economizado. A primeira estimativa contabiliza como frete aéreo apenas 10% dos itens atrasados pela produção. Já a segunda estimativa, mais pessimista, contabiliza 40% dos atrasos como sendo enviados via aérea. Esses resultados podem ser observados na Tabela 5.6.

Tabela 5.6 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/home m	Total economizado (min)	Economia semana	Economia ano
Homem hora	17,96	0,3	1075	321,9	16738,8
Hora-máquina	20	0,33	1075	358,3	18631,6
Total Insumo	37,96	0,63	2150	680,19	35369,9
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economia ano
Custo frete extra (10%)	0,16	0,1	25771	412,336	21441,5
Custo frete extra (40%)	0,16	0,4	25771	1649,344	85765,9
Total frete com frete 10%				1092,526	56811,4
Total frete com frete 40%				2329,534	121135,8

É possível observar na Tabela 5.6 que, somente alterando o modo de se programar, reduzindo o número de *setups* e melhorando o planejamento, o custo semanal da operação cai cerca de R\$ 680,19. Ao realizar-se uma previsão para o ano inteiro o custo cai cerca de R\$ 35.369,90. Ainda, ao adicionar o custo dos fretes extras realizados devido aos atrasos, o ganho da empresa aumenta bastante. No caso para apenas 10% do atraso contando como frete extra aéreo a economia já salta para R\$ 56.811,4. Já para o caso crítico, no qual 40% do atraso em peças é enviado de frete extra aéreo a economia para a empresa chega a R\$ 121.135,8 por ano.

A partir desses resultados, foi levantada a necessidade de alteração no custo de atraso de cada tipo de peça para que os tipos de peças com maior tempo de produção não fossem negligenciados pelo modelo, mesmo sendo peças mais caras. Essa alteração visou influenciar no sistema de tomada de decisão do algoritmo. Para que os dados fossem condizentes com a realidade, foi feita uma consulta com o setor de planejamento e controladoria<sup>10</sup>, na qual foram evidenciados os custos de atrasos para cada tipo de peça. Esses custos podem ser vistos na Tabela 5.7 e envolvem ressarcimento de clientes e perdas de negócios, não contabilizando o valor dos fretes.

<sup>10</sup> Setor de planejamento e controladoria – setor responsável por gerir a parte contábil da fábrica

Tabela 5.7 - Diferenças entre os custos de atraso para cada tipo de peça do sistema

Tipo	D	Custo
1	3	1
2	6	7
3	7	7
4	1	1
5	2	1
6	3	1
7	4	1
8	5	1
9	1	1
10	2	1
11	3	1
12	4	1
13	5	1

O vetor que representa a Tabela 5.7 pode ser visto em (5.3). Esse vetor mostra para o sistema que cada vez que uma peça do tipo 2 ou 3 atrasa o custo é aumentado em sete vezes, ao contrário das outras peças.

$$\text{Custo atraso peça} = [1 \ 7 \ 7 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1] \quad (5.3)$$

Assim como o primeiro teste realizado com todos os valores iguais a 1, o segundo teste foi bem sucedido e os períodos de fabricação de cada peça podem ser vistos na Tabela 5.8. Essa tabela mostra que todas as peças necessárias foram fabricadas, não havendo problemas na capacidade. Algumas peças avulsas aparecem no modelo pois estão dentro do erro tolerado. Esse erro é de  $1 \times 10^{-3}$ . Dessa vez foi utilizada uma capacidade de 2680 por período para atender os requisitos da produção.

A Tabela 5.8 ainda permite avaliar quando os itens foram entregues. O atraso das peças por período pode ser visto na Tabela 5.9.

Tabela 5.8 - Produção dividida por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	200	33260	34066	28900	46000
	2	2000	0	0	0	0
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	1235	0	37445	0	103
	6	38050	29675	0	15660	0
	7	0	0	8742	0	0
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	3073	0	1236	0	5150
	11	0	13560	0	24100	0
	12	20650	8650	21000	0	22152
	13	14000	12452	1148	25000	0

A Tabela 5.8 ainda permite avaliar quando os itens foram entregues. O atraso das peças por período pode ser visto na Tabela 5.9.

É possível notar a diferença nos tipos de peças atrasadas entre o primeiro modelo testado, que possui custo igual para todas as peças, e o segundo modelo testado com o custo diferenciado para as peças do tipo 2 e 3. Como o atraso foi recalculado para ser igual a 7 para esses tipos de peças, o programa preferiu produzi-las no primeiro período. O efeito colateral dessa produção é que itens do segundo período, sofrem um atraso de 2775 peças. Esse atraso é de 470 peças maior que do primeiro teste, que é de 2305. Com isso, é possível afirmar que em termos de resultados os dois modelos são praticamente iguais.

Salienta-se que, comparando o modelo proposto com o modelo utilizado atualmente pela empresa, é possível notar que a melhora foi grande. O atraso em número de peças caiu de 28076 peças para 2775 peças, o que, traduzido em termos percentuais, representa uma melhora de 90%. Essa melhora é traduzida em uma melhor entrega e consequentemente melhor utilização das máquinas pela empresa, aumentando sua eficiência. Na indústria automotiva, fornecedores com boas taxas de entrega são necessários devido ao comportamento *Lean*<sup>11</sup> das montadoras, que utilizam o mínimo de estoques possíveis em suas fábricas.

<sup>11</sup> Lean – Sistema de produção desenvolvido pela Toyota que foca em reduzir os desperdícios (GRAVES, 1981).

Tabela 5.9 - Atraso dividido por tipo e período

		Atraso(peças)				
		1	2	3	4	5
Tipo do produto	1	0	0	0	0	0
	2	0	0	0	0	0
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	0	0	0	0	0
	6	0	0	0	0	0
	7	0	0	0	0	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	1236	0	0	0
	11	0	0	0	0	0
	12	0	0	0	0	0
	13	0	1148	0	0	0

Com relação ao tempo, é possível notar que o atraso do segundo teste em tempo de produção é de 64 minutos. Já o do primeiro é de 1145 minutos. Isso prova que o modelo de produção privilegia o menor atraso em peças, mesmo quando o custo do atraso é variado. Tal objetivo pode ser visto na função objetivo na Equação (5.3), o que valida novamente a modelagem. Além disso, o tempo total gasto é menor que no primeiro período, totalizando uma sobra de 296 minutos do total de 12900 programado. Com relação ao modelo utilizado atualmente pela empresa, houve um ganho de 750 minutos para o tempo total de produção planejado.

Assim como no primeiro teste, é necessário avaliar os ganhos obtidos de forma numérica. A melhor forma para avaliá-los é transformando as melhorias em dinheiro. Para isso, pode-se somar a hora homem com a hora máquina economizada, além do custo do frete-extra. Para todos os testes utilizados os valores são iguais e foram fornecidos pela empresa. Os valores para cálculo podem ser vistos na página 63. Os resultados financeiros obtidos com esse modelo podem ser observados na Tabela 5.10.

Em comparação com o primeiro teste, existe uma diminuição dos ganhos para a empresa, isso porque o número de peças atrasadas é maior. Estendendo essa perda para o período de um ano pode-se calcular que a diminuição dos ganhos é de R\$ 2.667,00, ou seja, apenas uma pequena redução. Porém, comparando-se os resultados desse modelo com o utilizado atualmente pela empresa é possível perceber que os ganhos ainda continuam expressivos. Esses ganhos são estimados em R\$ 55.317,4 em um ano para o caso em que 10%



do frete é considerado como aéreo e R\$ 118.468,7 quando esse frete sobe de 10% para 40 % do total.

Tabela 5.10 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/homem	Total economizado (min)	Economia semana	Economia a ano
Homem hora	17,96	0,3	1046	313,8	16945,2
Hora-máquina	20	0,33	1046	345,18	18639,7
Total Insumo	37,96	0,63	2092	658,98	35584,9
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economia a ano
Custo frete extra (10%)	0,16	0,1	25301	404,816	21050,4
Custo frete extra (40%)	0,16	0,4	25301	1619,264	84201,7
Total frete com frete 10%				1063,796	55317,4
Total frete com frete 40%				2278,244	118468,7

Por último, é importante demonstrar que, novamente, o gráfico de demanda versus capacidade desse modelo encontra-se com uma tendência mais linear que o do modelo inicial. A figura do modelo atual da empresa pode ser vista na Figura 5.1 enquanto que a do modelo atual pode ser vista na Figura 5.4.




Figura 5.4 – Comparação de demanda x capacidade – alta

O terceiro e último teste elaborado com o conjunto de dados para demanda alta foi realizado variando-se além do custo por peça o custo do atraso por período. Esse novo de custo pode ser entendido facilmente, pois caso a peça atrase no dia 1, o custo de atraso diário é 1 vez o atraso da peças é de 1, enquanto que nos dias posteriores, seria de valores subsequentes, ou seja, no dia 2 o custo seria igual a 2. Essa alteração no atraso por dia visou direcionar o programa a aproveitar capacidades restantes nos primeiros dias e deixar os últimos com o maior tempo restante possível. Muitas vezes essa situação é vista na realidade. A equação que mostra esse a mudança do custo do atraso pode ser vista em (5.4), a qual mostra para o sistema que cada vez que uma peça do tipo 2 ou 3 atrasa, o custo é aumentado em sete vezes, ao contrário das outras peças.

$$\text{Custo de atraso por dia} = [1 \ 2 \ 3 \ 4 \ 5] \quad (5.4)$$

Para esse modelo foram realizados testes variando a capacidade de 2680 e 2660, sendo que para 2660, apesar de o *gap* relativo ser menor, o balanceamento entre os dias possui uma maior coerência. Essa linearidade nos valores de produção pode ser vista na Figura 5.5.




Figura 5.5 – Comparação de demanda x capacidade – alta

Assim como o primeiro teste e o segundo realizados, o terceiro teste foi bem sucedido e todas as peças necessárias foram produzidas. Os períodos de fabricação de cada peça podem ser vistos na Tabela 5.11. Essa tabela mostra que todas as peças necessárias foram fabricadas,

não havendo problemas na capacidade. Algumas peças avulsas aparecem no modelo pois estão dentro do erro tolerado. Esse erro é de  $1 \times 10^{-3}$ . Dessa vez foi utilizada uma capacidade de 2560 por período para atender os requisitos da produção.

Tabela 5.11 – Produção dividida pro tipo e período

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	200	33261	62965	0	46000
	2	0	0	2000	0	0
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	1241	0	14832	16312	6400
	6	38050	29675	0	15360	30
	7	0	0	3660	0	5082
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	4309	0	0	0	5150
	11	0	13560	0	24100	0
	12	29300	0	0	21000	22150
	13	14000	20290	0	18310	8

A Tabela 5.12 é um complemento da Tabela 5.11 e permite verificar qual foi o total de peças atrasadas e comparar com os métodos atualmente utilizado pela empresa em questão.

Tabela 5.12 – Atraso dividido por tipo e período

		Atraso(peças)				
		1	2	3	4	5
Tipo do produto	1	0	0	0	0	0
	2	2000	2000	0	0	0
	3	0	0	0	0	0
	4	0	0	0	0	0
	5	0	0	0	0	0
	6	0	0	0	0	0
	7	0	0	0	0	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	0	0	0
	12	0	0	0	0	0
	13	0	0	0	0	0

Em comparação com o modelo utilizado pela empresa, o atraso no número de peças cai de 28076 para 4000 peças, ou seja, uma melhoria de 85%. Novamente, o modelo tem sua eficácia comprovada. Além disso, como o atraso varia conforme o dia de produção, o sistema optou por atrasar as peças nos dias 1 e 2, de forma a diminuir o impacto. Em comparação com os outros dois testes efetuados com o modelo criado, o modelo atual resultou em torno de 1500 peças de atraso menos eficiente, o que, em porcentagem total, chega a 80%. Assim como no primeiro modelo, a peça com maior tempo de produção ficou atrasada, mesmo ela possuindo o maior custo de atraso. Pode ser observado então, que para resolver os problemas de atraso da peça número dois, o modelo com variação apenas no custo da peça é o melhor a ser utilizado.

Com relação aos tempos produtivos, é possível notar que o atraso do terceiro teste em tempo de produção é de 972 minutos. O do primeiro teste é de 1145 minutos e o do segundo é de 64 minutos. Isso prova que o modelo de produção com variação do custo do atraso em dias gera uma perda substancial em número de minutos. Além disso, o tempo total gasto é maior que no primeiro período, totalizando uma sobra de 126 minutos do total de 12800 programado, contra 296 do segundo modelo, com 12900 programado. Com relação ao modelo utilizado atualmente pela empresa, houve um ganho de 850 minutos para o tempo total de produção planejado, sem contar o tempo não utilizado.

Assim como no primeiro teste, essa melhora no atraso e no tempo de produção pode ser em desdobrada termos financeiros. Para isso, pode-se somar a hora homem com a hora máquina economizada. Além disso, a redução na necessidade de frete aéreo também pode ser calculada. Esses resultados podem ser observados na Tabela 5.13 e podem ser comparados com os outros dois testes já realizados.

Tabela 5.13 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/home m	Total economizado (min)	Economia semana	Economi a ano
Homem hora	17,96	0,3	976	292,8	15811,2
Hora-máquina	20	0,33	976	322,08	17392,3
Total Insumo	37,96	0,63	1952	614,88	33203,5
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economi a ano
Custo frete extra (10%)	0,16	0,1	24076	385,216	20031,2
Custo frete extra (40%)	0,16	0,4	24076	1540,864	80124,9
Total frete com frete 10%				1000,096	52005,0
Total frete com frete 40%				2155,744	112098,7

Em comparação com os outros dois testes, é possível notar que ocorre uma diminuição dos ganhos para a empresa, isso porque o número de peças atrasadas é maior, saindo de 2775 para 4000. Estendendo essa perda em comparação com o segundo modelo, para o período de um ano, pode-se calcular que a diminuição dos ganhos é de R\$ 6370,00, uma diferença considerável. Porém, comparando-se os resultados desse modelo com o utilizado atualmente pela empresa é possível perceber que os ganhos ainda continuam expressivos. Esses ganhos são estimados em R\$ 52.005,0 em um ano para o caso em que 10% do frete utilizado ser aéreo e R\$ 112.098,7 quando a porcentagem despachada por frete aéreo sobe de 10% para 40 % do total.

Por fim, os três testes realizados para demanda alta apresentam ganhos de mais de 80% no atraso de peças. Ainda, o ganho dos três modelos também ultrapassa a casa dos R\$ 100.000 em um ano se considerado o pior caso, qual seja, a utilização do frete aéreo, com 40% de atraso. Outro ponto importante é a adição da restrição de capacidade ao modelo atual, não vista no modelo atual da fábrica. Por isso, os três testes podem ser considerados como um sucesso.

## 5.2 Análise de demanda média

Os dados utilizados para simular uma demanda média possuem uma necessidade total de produção de 372.940 peças para os cinco dias, dividindo-se esse valor por cinco encontra-se o valor diário de 74.588 peças/dia. Nos casos de demanda alta e baixa, os valores diários de produção são de: 89.721 e 48.623 peças/dia, respectivamente. Assim como no caso dos testes com alta produção, primeiramente os métodos atuais utilizados pela empresa foram analisados para depois incluir o modelo de otimização desenvolvido.

Também, o conjunto de dados de um ambiente de produção média visa verificar se esse modelo criado funciona bem em outro tipo de condição além da demanda alta. Três variações nesse modelo foram testadas para esse tipo de demanda, repetindo os testes realizados na seção 5.1. Esses testes são: custo de atraso das peças igual a 1 para o primeiro caso, custos variados das peças para o segundo caso e custo dos dias e das peças diferentes para o terceiro caso. Os resultados dos três modelos estão tabelados ao final da seção para melhorar a compreensão.

O conjunto de dados testado para essa subseção pode ser visto na Tabela 5.14, sendo dividida entre os períodos de necessidade no eixo  $x$  e entre as famílias dos produtos existentes no eixo  $y$ . Esse modelo, apesar de possuir um número total menor de peças a serem fabricadas

que o de alta demanda, possui produtos que demoram mais para serem fabricados. O principal fator desse tempo de fabricação elevado deve-se ao fato de que o número de peças do tipo 2 e 3 a serem fabricados é alto e chega a 12550 no total. Além disso, esse modelo é o único a possuir a demanda pela peça 3, a mais demorada.

A partir dos dados obtidos da Tabela 5.14, o planejamento utilizado atualmente consiste em multiplicar o número de lotes vezes o tempo de fabricação e considerar todos os *setups* como existentes. Esse planejamento gera um alto tempo de produção, o que já pode ser visto no caso de alto volume de produção. Nesse caso, ou seja, 74.588 peças por dia, contendo 47 lotes a serem fabricados em cinco dias, o tempo total de fabricação incluindo o *setup* seria de 13.421 minutos. Para efeitos de comparação, no caso da demanda alta esse tempo foi de 13.653 minutos. No caso da demanda média, o valor traduzido em horas seria igual a 44,7 horas por dia de máquinas e mão de obra direta. Assim como na demanda alta, a capacidade do setor pode exceder 24 horas por dia pois existe mais de uma máquina para se trabalhar. Apesar disso, o modelo utilizado foi o *single machine*, pois ele permite uma melhor análise entre os três tipos de demanda analisados nessa dissertação. Os valores para esse tipo de programação podem ser vistos na Tabela 5.15.

Tabela 5.14 - Demanda média dos produtos dividida em períodos e famílias

		Demanda (dias)				
		1	2	3	4	5
Tipo do produto	1	8600	8600	34400	0	0
	2	0	1400	0	4500	5800
	3	850	0	0	0	0
	4	2160	0	0	0	0
	5	12100	0	0	2600	0
	6	25876	23438	26413	39351	27000
	7	0	4070	1150	0	3502
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	24260	28600	3000
	12	3225	12000	14150	17300	0
	13	12500	0	12500	0	12500

Tabela 5.15 - Dados de produção para o modelo atual contando todos os setups - média

Demanda dia						
	1	2	3	4	5	Total Fim
Peças	66410	49508	112873	92351	51802	372944
Minutos	2037	1484	2850	3051	2589	12011
Setup qts	9	6	14	10	8	47
Setup min	270	180	420	300	240	1410
Total dia min	2307	1664	3270	3351	2829	13421
Capacidade	2685	2685	2685	2685	2685	13425
Atraso			585	666	144	1395

Como pode ser observado na Tabela 5.15, apesar da capacidade de 2685 minutos por dia, assim como na demanda alta, ainda haveria atrasos na produção de 1395 minutos, distribuídos em 3 dias. Esse atraso convertido em peças equivale, em média, a 41.184 unidades. Para chegar a esse número, utilizou-se a regra de proporcionalidade. Um exemplo dessa regra é apresentado a seguir, onde  $(92531-x)$  é o atraso.

Um outro modo de se observar a produção é o que considera apenas o dia e o número de *setups*, aproveitando estes últimos. O modelo utiliza os *setups* que ocorrem dentro do dia. Ele não é capacitado mas, mesmo assim, ele pode ser considerado como uma melhoria em relação ao modelo anterior. É possível observar essa melhoria em termos de tempo na Tabela 5.16. Nesse caso, o tempo total consumido é de 12610 minutos, que traduzidos em números de hora, atingem 42,06 horas de trabalho por dia. Comparando-se com o modelo anterior é possível computar o ganho de cerca de 2 horas de produção a partir do modelo inicial, além da diminuição do total de minutos consumidos de parte da mão de obra direta e de máquinas.

Tabela 5.16 - Modelo de programação atual da fábrica considerando aproveitamento de setups- média

Demanda dia						
Dia	1	2	3	4	5	Total Fim
Peças	66410	49508	112873	92351	51802	372944
Minutos	2037	1484	2850	3051	2589	12011
Setup qts	6	3	3	4	4	20
Setup min	180	90	90	120	120	600
Total dia min	2217	1573	2940	3171	2709	12610
Capacidade	2522	2522	2522	2522	2522	12610
Atraso	0	0	418	649	187	1254

Para esse método, o atraso estimado médio seria de aproximadamente 1254 minutos, desigualmente distribuídos entre os dias. Porém, o atraso em peças seria de 38.475, menor que o modelo anterior. É verificado que o tempo de fabricação varia de um dia para o outro, o que acaba por gerar problemas de capacidade para a fábrica. Por exemplo, no dia 4 a demanda em minutos é de 3.171, enquanto que, no dia 2, a demanda é de 1.012 minutos. A diferença entre esses dois dias é de 2.159 minutos. Essa diferença gera falta de produção para um dia e excesso para o outro, desbalanceando a programação por datas.




Figura 5.6 - Comparação de demanda x capacidade para demanda média.

Essa variação pode ser vista na Figura 5.6, na qual a linha azul mostra a capacidade disponível em minutos e a linha laranja representa a demanda dia-a-dia. O eixo  $x$  do gráfico novamente traduz o tempo em dias de produção.

Com a Figura 5.6 pode-se observar que, caso a produção fosse seguida conforme a programação, o não ocorreria atendimento de 100%. Isso porque, como a produção do terceiro, quarto e quinto dias são maiores que a capacidade, ocasionaria atrasos nos pedidos. É possível inferir que o modelo não é capacitado, ou seja, permite a alocação de demanda onde não existe capacidade. Portanto, assim como na solução para o modelo de demanda alta, a solução foi a adição da restrição de capacidade. A equação que restringe a capacidade é mostrada em (5.5) e pode ser vista com mais detalhes no capítulo 4 da dissertação.

$$\sum_i \sum_k t_{prod_{i,k}} * x_{i,j,k} + \sum_k t_{setup_k} * h_k + w_j - w_{j-1} = C \quad \{j = 1, 2, \dots, T\} \quad (5.5)$$



Para se testar o modelo, foi definida, então, uma capacidade um pouco maior que o mínimo necessário, pois, com isso, o modelo não seria encerrado por problemas na restrição da Equação (5.6), sendo de 2600 minutos por dia, ou seja, 13000 minutos para os 5 dias. Apesar da quantidade ser de 13000 para os 5 dias, comparando-se com o modelo utilizado atualmente pela empresa, ocorre uma diferença de 650 minutos, ou seja, 4,6%, o que já pode ser considerado como um ganho inicial. O primeiro teste realizado com os dados para a demanda média e com o modelo criado considerou os pesos dos atrasos dos produtos como sendo iguais para todos, seguindo a mesma sequência lógica que na produção alta. A equação dos custos dos atrasos para produtos pode ser observada em (5.6). O custo dos atrasos por dia pode ser visto em (5.7).

$$\text{Custo atraso peça} = [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1] \quad (5.6)$$

$$\text{Custo atraso dia} = [1 \ 1 \ 1 \ 1 \ 1] \quad (5.7)$$

O teste com os novos vetores de custo apresentou um resultado satisfatório. Os dias de fabricação e a quantidade produzida de cada peça encontram-se demonstrados na Tabela 5.17. Essa tabela mostra que todas as peças necessárias foram fabricadas, não havendo problemas na capacidade. Esse erro é de  $1 \times 10^{-3}$ .

Tabela 5.17 - Valores de produção por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	8600	42999	0	0	0
	2	3185	0	0	0	8515
	3	0	850	0	0	0
	4	2160	0	0	0	0
	5	12100	0	2600	0	0
	6	25876	25392	24480	66349	0
	7	0	4070	4682	0	0
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	24260	31600	0
	12	3226	11999	31443	2752	0
	13	12500	0	12500	0	12500

Assim como no caso de alta demanda, quando os custos das peças forem todos iguais, o atraso ocorre somente nas peças com maior tempo de produção, ou seja, peças 2 e 3, totalizando 3566. Esse atraso é de 850 unidades do tipo 3 no período 1, e de 2716 unidades do tipo 2 no período 4. Como o sistema visa reduzir o número de peças atrasadas, ele opta por deixar de fabricar as com maior tempo de produção. Essa diferença dos tempos de produção é grande, sendo que o produto 1 possui tempo de produção de 0,0271 minuto enquanto que a do tipo 3 é de 0,460 minuto. Portanto, a peça 2 é quase 20 vezes mais lenta de produzir que a 1.

Dessa forma, ao analisar o número de peças atrasadas do modelo original com o modelo proposto, é possível relatar grande melhora. No modelo original, o atraso é de 41184 peças, enquanto que no modelo otimizado ele é de 3566 peças, o que, traduzido em termos percentuais, representa uma melhora de 92%.

Também é importante ressaltar que o programa acaba por produzir 375743 peças, um pouco a mais que a demanda enviada. Isso ocorre porque existe um *gap* na solução de 0.001, que permite ao sistema encontrar uma solução viável com tempo disponível mesmo que para isso ele acabe por produzir mais para o período seguinte. Essa diferença é encontrada na peça do tipo 12 e possui 2745 peças a mais, sendo produzida no período 4.

Ademais, ao se retirar essa peça da análise, o ganho em tempo seria de 68 minutos de produção e 30 minutos de *setup*, o que equivaleria a 98 minutos no total do dia 4. Isso levaria a uma sobra de produção de 295 minutos, que poderiam ser usados para outras atividades da fábrica. Sem considerar essa sobra, o total seria de 197 minutos. Porém, como o programa considerou essa produção, tanto o gráfico como a análise de demanda foram feitos com base no adquirido via sistema. Na prática, a análise poderia ser um pouco diferente, pois o programador poderia definir que o estoque dessa peça no período quatro não fosse necessário.

Para verificar se a produção ficou nivelada foi criado um gráfico que apresenta os valores de demanda versus capacidade entre os períodos. Esse gráfico pode ser visto na Figura 5-7. Como já visto antes, o nivelamento permite suavizar o modo como o setor é programado, além de permitir uma utilização da capacidade de forma mais racional para o programador.

Como pode ser observado na Figura 5.7, a capacidade estimada por dia e a utilizada divergem em alguns casos. Isso acontece devido ao fato do modelo possuir a programação de folgas e atrasos na produção. Portanto, os minutos a mais observados no dia 1, 2, 3 são repassados de forma contínua para o quarto dia. Isso não atrapalha o resultado final do sistema criado, pois ele é capacitado e deve fabricar todas as peças dentro do tempo pré-determinado. Essa característica ocorre na sua forma prática para que o fim da operação de algum lote de

produtos não seja interrompido. Como já mencionado anteriormente, a criação de folgas entre os períodos resolve o problema de tempos vazios existentes nos fins dos períodos, defeito comum em modelos CLSP tradicionais.




Figura 5.7 - Comparação de demanda x capacidade para demanda média.

Essa melhora foi, por último, contabilizada para valores em moeda, o que permite avaliá-la em comparação com as demais de forma mais racional. Os dados utilizados para realizar essa conta podem ser vistos na demanda alta<sup>12</sup> e são resultado da soma das economias geradas com a redução de utilização de tempo de mão de obra, tempo de máquina e os fretes-extra. No caso dos fretes-extra, são testadas as hipóteses com 10% ou 40% da produção sendo enviada de forma aérea, a mais cara. Esses resultados podem ser observados na Tabela 5.18.

Tabela 5.18 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/home m	Total economizado (min)	Economia semana	Economia ano
Homem hora	17,96	0,3	622	186,6	10076,4
Hora-máquina	20	0,33	622	205,26	11084,0
Total Insumo	37,96	0,63	1244	391,86	21160,4
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economia ano
Custo frete extra (10%)	0,16	0,1	37618	601,888	31298,2
Custo frete extra (40%)	0,16	0,4	37618	2407,552	125192,7
Total frete com frete 10%				993,748	51674,9
Total frete com frete 40%				2799,412	145569,4

<sup>12</sup> Custos: Hora-homem : R\$ 17,96, Hora-máquina : R\$ 20,00, Frete-extra: R\$ 0,16 a mais por peça enviada.

A Tabela 5.18 demonstra os resultados obtidos com a utilização do programa de otimização: com ele o custo de operação cai cerca de 390,0 por semana sem adicionar os valores dos fretes-extra. Expandindo esse valor para um ano inteiro, a economia chega a R\$ 21,160,4. Ainda, com a adição dos fretes para 10% do total, a economia para a empresa mais que dobra, chegando a R\$ 51.674,2. Já para o caso crítico, no qual 40% do atraso em peças é enviado via frete extra aéreo, a economia para a empresa chega a R\$ 145.569,8 por ano. Assim como no caso da alta demanda, todos as economias são calculadas a partir dos valores encontrados no modelo tradicional utilizado pela empresa.

Vários fatores relacionados a economia com programação, no entanto, não podem ser vistos ou mensurados. Um deles é a necessidade de hora extra caso as operações a frente da analisada fiquem sem produtos para fabricar devido a uma programação ineficiente. Além disso, outros custos, como de energia, alimentação e transporte são dificilmente mensurados. Por isso, mesmo que o ganho quantitativo seja de no máximo R\$ 114.569,00, o ganho real pode ser muito maior. Tais áreas relacionadas à programação que perdem eficiência podem ser vistas em Graves (1981).

Como, novamente, os atrasos ocorreram nas peças 2 e 3, foi testado o modelo com alteração nos custos dessas duas peças mais lentas para se produzir para reduzir o problema. Essa alteração visou influenciar no sistema de tomada de decisão do algoritmo.

O custo estimado para as peças do tipo 2 e 3 é de aproximadamente 7 vezes o valor dos outros, sendo, portanto, muito mais custosas caso haja atraso; essa diferença no custo advém de uma comparação dos custos de fabricação entre as peças, sendo 1 o valor normal de uma peça para ser fabricada. Essa alternativa força o programa a tentar zerar esses atrasos, apesar de que em alguns casos não será possível. Os novos vetores de custo podem ser observados nas equações (5.8) e (5.9).

$$\text{Custo} = [1 \ 1 \ 1 \ 1 \ 1] \quad (5.8)$$

$$\text{Custo atraso peça} = [1 \ 7 \ 7 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1] \quad (5.9)$$

Assim como o primeiro teste realizado com todos os valores iguais a 1, o segundo teste obteve sucesso e todas as peças necessárias foram programadas dentro do tempo estimado. Os períodos de fabricação de cada peça podem ser vistos na Tabela 5.19. Algumas peças avulsas aparecem produzidas no modelo pois estão dentro do erro tolerado. Esse erro é de  $1 \times 10^{-3}$ .

Dessa vez, foi utilizada uma capacidade de 2616 por período para atender os requisitos da produção.

Tabela 5.19 - Valores de produção por período e tipo

		PRODUÇÃO (DIAS)				
		1	2	3	4	5
TIPO DO PRODUTO	1	8600	22055	20945	0	0
	2	1400	0	4500	0	5800
	3	850	0	0	0	0
	4	2160	0	0	0	0
	5	12100	0	0	2600	0
	6	25876	49868	0	65844	489
	7	0	5220	0	0	3503
	8	1099	0	0	0	0
	9	0	0	0	0	63
	10	0	0	0	0	0
	11	0	0	24260	29189	2411
	12	3338	24260	0	17300	0
	13	12500	0	12500	0	12500

Diferentemente das outras hipóteses testadas, não ocorre nenhum atraso em peças, ou seja, há uma redução de 100% no atraso em número de peças. Isso prova a eficácia de se colocar um peso maior em peças que possuem maior tempo de fabricação. O motivo deve-se à equação objetivo, que apesar de reduzir o atraso no geral, considera todas as peças como iguais. Quando as peças são consideradas iguais, o programa tende a produzir primeiro as de menor tempo de produção, realizando assim uma otimização intuitiva. Essa diferença dos tempos de produção é grande, sendo que o produto 1 possui tempo de produção de 0,0271 minutos enquanto que a do tipo 2 é de 0,2430 minutos. Portanto, a peça 2 é quase 9 vezes mais lenta de produzir que a 1. No chão de fábrica analisado, a produção de peças grandes sempre é relegada ao segundo plano. Como os valores de atraso são alterados, o programa privilegia as peças maiores para não sofrer com esse problema.

Traduzindo os valores da Tabela 5.19 para tempo é possível observar que a produção ficou nivelada se comparada com a capacidade, isso porque o gráfico da Figura 5-8 apresenta uma tendência muito mais linear que o apresentado na Figura 5-6.




Figura 5.8 - Comparação de demanda x capacidade para demanda média

Assim como nos outros gráficos analisados, após a otimização ser realizada, notou-se diferenças entre programação disponível em tempo para o dia e a utilizada. Isso ocorreu pois o sistema de folga novamente é o responsável por esses eventos. Essas folgas podem ser observadas na Figura 5.8 nos dias 1, 3, 4. Tais diferenças não interrompem o funcionamento do sistema.

Comparando esse teste com o primeiro com os custos todos iguais, é possível inferir da Tabela 5.19 que houve uma melhora no tempo total. Esse tempo é de 13.080 minutos para o modelo testado, enquanto que no modelo utilizado pela empresa é de 13.425. A diferença é de 345 minutos, ou seja, quase um terço de um dia de melhora. Essa diferença, em termos percentuais, equivale a 3,4%, o que representa uma melhora de produtividade difícil de conseguir na maioria das empresas, como pode ser visto na Figura 5.3, na análise da alta demanda. Essa figura mostra a evolução da taxa de produtividade no trabalho da indústria nos anos antes de 2014.

No quesito financeiro também foi possível notar uma economia na hora-máquinas e na hora-homem, assim como no custo total dos fretes-extra. Para realizar o cálculo, novamente, foram utilizadas as mesmas bases, sendo de R\$ 20,00 para hora máquina e de R\$ 17,96. Já para o caso do frete aéreo, ele custa 0,16 centavos a mais por peça que o utiliza. Os resultados financeiros podem ser observados na Tabela 5.20

Tabela 5.20 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/home m	Total economizado (min)	Economia semana	Economia ano
Homem hora	17,96	0,3	601	180,3	9736,2
Hora-máquina	20	0,33	601	198,33	10709,8
Total Insumo	37,96	0,63	1202	378,63	20446,0
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economia ano
Custo frete extra (10%)	0,16	0,1	41184	658,944	34265,1
Custo frete extra (40%)	0,16	0,4	41184	2635,776	137060,4
Total frete com frete 10%				1037,574	53953,8
Total frete com frete 40%				3014,406	156749,1

A Tabela 5.20 demonstra que a economia anual chega a R\$ 20466,00, sem incluir a redução com a diminuição dos fretes-extra. Com a análise adicionando 10% do total atrasado entregue como frete extra, o valor chega a R\$ 53.953,80, enquanto que, no caso mais crítico, de 40% do atraso entregue como frete extra, o valor atinge R\$ 156.749,1, um saldo de suma importância para o resultado fabril.

Como mencionado anteriormente, outras economias advindas da redução do atraso na entrega são difíceis de mensurar. Um caso de melhora interessante, que se encaixa nessa redução, é a ociosidade de linhas de clientes, que podem ficar paradas devido à não entrega dos itens.

Apesar de o atraso ter sido zerado, foi realizado outro teste, com o custo aumentando por dia. O interesse em realizar testes consiste demonstrar como se comporta o modelo de otimização com essa alteração. Além disso, com a realização desse teste, a comparação entre os três tipos de demandas analisados fica mais coerente.

A mudança no modelo possui fácil interpretação, pois nela o atraso em dias, que antes se mantinha inalterado, agora aumenta. Isso faz com que as peças que possuem custo maior que 1 sejam multiplicadas junto com o aumento do custo diário. Por exemplo, caso uma peça com o custo 7 atrase no segundo dia, possuirá um peso de atraso de 14 para o programa. Dessa forma, é esperado que os atrasos concentrem-se no primeiro dia, aproveitando assim o resto da capacidade ociosa. Muitas vezes, essa situação em que o atraso no primeiro dia é priorizado acontece na realidade do sistema estudado - a equação que mostra essa mudança do custo do atraso pode ser vista em (5.10). Essa equação mostra para o sistema que, cada vez que uma peça

do tipo 2 ou 3 atrasa, o custo é aumentado em sete vezes, ao contrário das outras peças. Os vetores de custo peça atraso e custo dia podem ser observados nas equações (5.10) e (5.11).

$$\text{Custo} = [1 \ 2 \ 3 \ 4 \ 5] \quad (5.10)$$

$$\text{Custo atraso peça} = [1 \ 7 \ 7 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1] \quad (5.11)$$

Para esse teste, novamente, não houve problemas na produção das peças, sendo 100% entregue. O período de fabricação de cada uma pode ser visto na Tabela 5.23. Algumas peças avulsas aparecem no modelo pois estão dentro do erro tolerado. Esse erro é de  $1 \times 10^{-3}$ . Para esse teste foi utilizada uma capacidade de 2600 por período.

Tabela 5.21 - Valores de produção por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	6553	10927	34120	0	0
	2	5900	0	0	0	5809
	3	0	850	11	0	6
	4	2160	0	0	0	0
	5	12100	0	0	2600	0
	6	25875	23439	26427	39337	27000
	7	0	4070	1150	0	3502
	8	0	1099	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	24260	31476	124
	12	0	15252	14123	17300	0
	13	0	22121	2879	0	12500

Nesse caso, diferentemente dos outros da demanda média o atraso em peças foi alto. Essa verificação pode ser feita através da Tabela 5.22.

No entanto, em comparação com o modelo utilizado pela empresa, o atraso no número de peças cai de 41.184 para 19.722 peças, ou seja, uma melhoria de 53%. Apesar disso, a eficácia da modelagem pode ser comprovada. Ao comparar o modelo com atraso apenas nas peças 2 e 3, ele pode ser caracterizado como ineficiente, não sendo capaz de reduzir todo o atraso. Como esperado, todos os atrasos ocorrem no primeiro dia, sendo de vários tipos de peças e não somente 2 e 3, pois o sistema sabe que nos outros o custo do atraso cresce



vertiginosamente. Pode ser observado, então, que, para resolver os problemas de atraso da peça número 2 e 3, o modelo com variação apenas no custo da peça, o segundo testado para demanda média, é o melhor a ser utilizado. É interessante salientar, também, que, apesar de haver vários lotes de peças com alto tempo de fabricação, o programa continua a trabalhar de forma correta, ou seja, otimiza a produção.

Tabela 5.22 - Atraso em cada período por tipo

		Atraso (dias)				
		1	2	3	4	5
Tipo do produto	1	2047	0	0	0	0
	2	0	0	0	0	0
	3	850	0	0	0	0
	4	0	0	0	0	0
	5	0	0	0	0	0
	6	1	0	0	0	0
	7	0	0	0	0	0
	8	1099	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	0	0	0
	12	3225	0	0	0	0
	13	12500	0	0	0	0

Com relação aos tempos do programa, é possível notar que o atraso do terceiro teste em tempo de produção é de 990 minutos. O do primeiro teste é de 1050 minutos e o do segundo é de 0 minutos. Isso prova que o modelo de produção com variação do custo do atraso em dias gera uma perda substancial em número de minutos. Além disso, o tempo total gasto é maior que no primeiro período, totalizando uma sobra de 169 minutos do total de 13000 programados, em face de 345 minutos do segundo modelo, com 13080 programados. Com relação ao modelo utilizado atualmente pela empresa, houve um ganho de 425 minutos para o tempo total de produção planejado, sem contar o tempo que sobra ao fim da programação.

Novamente, ao se analisar o gráfico de “demanda x capacidade” na Figura 5.9, é importante observar que a linha que determina a demanda (laranja) possui uma tendência muito mais linear que o gráfico da Figura 5.6, que utiliza os dados atuais do setor.

Outra análise importante a se fazer é verificar se a produção ficou nivelada, isto é, apresentando valores de demanda versus capacidade plausíveis entre os períodos. Para isso, foi

criado um gráfico com os valores de produção mais *setup* de cada período e sua capacidade, o qual pode ser visto na Figura 5.9. O nivelamento da produção ajuda na programação por parte do programador em si. Além disso, ela permite que a produção seja balanceada.

Ainda na Figura 5.9, é possível observar que capacidade estimada dia e a utilizada divergem em alguns casos. Isso acontece em decorrência de o modelo possuir a programação de folgas e atrasos na produção como já comentado no outro modelo testado. A folga, representada por  $z$ , pode ser vista na Equação 5.6.




Figura 5.9 - Comparação demanda x capacidade média

Assim como no primeiro teste, essa melhora no atraso e no tempo de produção pode ser desdobrada em ganhos tangíveis, ou seja, utilizando o dinheiro como base. Para evitar redundância de informação, é importante ressaltar que os dados utilizados para a execução do cálculo dos ganhos são os mesmos que para outros modelos<sup>13</sup>, permitindo, dessa forma, a padronização de informações durante toda a análise. Os resultados financeiros obtidos podem ser observados na Tabela 5.23.

É possível observar na Tabela 5.23 que a redução de custo fica basicamente igual ao do modelo com custos fixos ao se analisar a questão de economia em hora-máquina e hora-homem. Porém, os custos com frete extra levam a uma economia menor que nos dois primeiros testes. O custo semanal da operação é reduzido em R\$ 343,00 ao se utilizar esse modelo de otimização. A expansão para um ano de operação sem a adição da economia com os fretes-extra permite

<sup>13</sup> Custos: Hora-homem : R\$ 17,96, Hora-máquina : R\$ 20,00, Frete-extra: R\$ 0,16 a mais por peça enviada

chegar a cifra de R\$ 20.207,00. Dessa forma, mesmo que o ganho obtido nesse teste seja menor que nos outros dois modelos testados, ele ainda continua alto.

Tabela 5.23 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/homem	Total economizado (min)	Economia semana	Economia ano
Homem hora	17,96	0,3	594	178,2	9622,8
Hora-máquina	20	0,33	594	196,02	10585,1
Total Insumo	37,96	0,63	1188	374,22	20207,9
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economia ano
Custo frete extra (10%)	0,16	0,1	21462	343,392	17856,4
Custo frete extra (40%)	0,16	0,4	21462	1373,568	71425,5
Total frete com frete 10%				717,612	37315,8
Total frete com frete 40%				1747,788	90885,0

Ainda, com a adição da economia gerada pela redução dos fretes aéreos a vantagem para a firma chega a R\$ 90885,8 por ano. Comparando, o primeiro modelo testado para demanda média, com custos iguais para as peças, apresentou uma redução em termos absolutos de R\$ 145.569,4, enquanto que no modelo com o custo das peças variando apresentou uma redução de 156749,1, e no, modelo atual, foi de R\$ 90885,00. Todas as economias são calculadas a partir do modelo original utilizado pela empresa.

É possível concluir, então, que os três modelos apresentam ganhos, em relação ao modelo de programação atual, que equivalem a valores de mais de 50% em redução no atraso de peças. Por isso, os modelos para demanda média são efetivos, assim como os de demanda alta. O último conjunto de dados que será testado representa a demanda baixa.

### 5.3 Análise de demanda baixa

Os dados utilizados para simular uma demanda baixa possuem uma necessidade total de produção de 243.115 peças para os cinco dias. Dividindo-se esse valor por cinco, encontra-se o valor diário de 48.623 peças/dia. Nos casos de demanda alta e média, os valores diários de produção são superiores, sendo de 89.721 e 74.588 peças/dia, respectivamente. Da mesma

forma que o procedimento utilizado nas análises dos outros tipos de demanda, os métodos atuais da empresa são analisados antes de se testar o modelo proposto. Esse procedimento serve para que seja possível ocorrer uma comparação do estado atual e do estado futuro da programação no setor de retificação. Além disso, para padronizar as análises e facilitar o entendimento por parte do interlocutor, a análise dos dados de demanda baixa é dividida em três tipos de testes, igual ao ocorrido nas outras seções.

O primeiro teste utiliza tanto os custos de produtos como o custo diários iguais a 1. O segundo varia os custos das peças mantendo os atrasos por dia iguais a 1. Por último, o terceiro modelo varia tanto o custos das peças individualmente como o dos períodos relacionados e tem como objetivo principal aproveitar melhor os primeiros dia, deixando os dias finais com mais capacidade.

Tabela 5.24 - Demanda baixa

		Demanda (dias)				
		1	2	3	4	5
Tipo do produto	1	27480	8600	8600	16500	17200
	2	1853	740	4100	0	1190
	3	0	0	0	0	0
	4	6800	0	0	0	0
	5	0	0	0	0	0
	6	1000	12938	14038	0	14700
	7	0	0	0	1150	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	600	0	0	0	0
	12	8650	10950	38500	8650	0
	13	0	0	0	25920	12960

Os dados testados para essa subseção advém de uma demanda baixa e podem ser vistos na Tabela 5.24, sendo divididos entre os períodos de necessidade no eixo  $x$  e entre as famílias dos produtos existentes no eixo  $y$ . Essa série possui uma quantidade de peças a serem produzidas bem menor que nos outros casos. Além disso, ela também possui uma menor variedade de produtos, o que em teoria facilita a programação, pois a quantidade de setups é menor. Pode-se observar que as peças do tipo 3, 5, 8, 9, 10 não são fabricadas em nenhum período. Essa condição, a princípio, ajudaria a diminuir a quantidade de *setups* a ser realizada por período. É importante lembrar, no entanto, que a demanda de peças do tipo 2, de alta tempo

de fabricação, é elevada, chegando a 7883 unidades. Tal demanda, junto com um menor número de minutos por período, pode tornar o sistema difícil de ser otimizado.

O primeiro modelo utilizado pela empresa, também o mais antigo, encontra a capacidade necessária através de multiplicação do número de peças pelo seu tempo de produção e contabiliza todos os setups necessários para o período. Os tamanhos dos lotes para a demanda baixa podem ser vistos no anexo 3. Assim como nos dois últimos casos, é importante notar que o total de atraso desse primeiro método, em teoria, é o que gera mais atraso, pois ele considera todos os *setups* como existentes. Nesse caso, ou seja, 48.623 peças por dia, contendo 35 lotes a serem fabricados em cinco dias, o tempo total de fabricação incluindo o *setup* seria de 9.281 minutos. Traduzindo-se em horas, seria igual a 30,93 horas por dia, bem menor que os outros dois modelos estudados. O primeiro utiliza 45,5 horas de trabalho por dia, demanda de 89.721 peças por dia, e o segundo com 44,3 horas por dia e demanda de 74.588 peças por dia.

Como o número de horas por dia excede as 24, é importante ressaltar que mais de uma máquina pode ser colocada em operação caso seja necessário. Apesar disso, como em todos os outros casos, o algoritmo continua sendo do tipo *single machine*. Os valores obtidos com essa programação podem ser vistos na Tabela 5.25.

Tabela 5.25- Dados de produção para o modelo atual contando todos os setups - baixa

Demanda dia						
Dia	1	2	3	4	5	Total Fim
Peças	46383	33228	65238	52220	46050	243119
Minutos	1660,689	964,5412	2485,412	1592,379	1527,901	8231
Setup qts	9	6	8	6	6	35
Setup min	270	180	240	180	180	1050
Total dia min	1931	1145	2725	1772	1708	9281
Capacidade	1856	1856	1856	1856	1856	9280
Atraso	75		869			944

Da Tabela 5.25 é possível deduzir que, apesar de ter sido definida uma capacidade de 1856 minutos e que atende à demanda total, ainda haveria atrasos na produção na ordem de 1395 minutos, distribuídos em 2 dias. Esse atraso, convertido em peças, seria, em média, de 20804 unidades. Para realizar o cálculo do atraso em número de peças foi utilizada a regra de proporcionalidade já proposta nas análises dos outros tipos de demandas.

O segundo tipo de método utilizado pela empresa para a programação consiste em aproveitar os *setups* ocorridos dentro do período, dessa forma, todas os tipos de peças no mesmo *setup* seriam feitas em sequência, o que gera uma economia no tempo produtivo. Apesar dessa economia, o método ainda não usa o conceito de capacidade e acaba por gerar os atrasos vistos na Tabela 5.25. Utilizando esse método, o tempo total consumido é de 8.710 minutos, que, traduzidos em números de horas, chegam a 29 horas de trabalho por dia. Comparando-se com o modelo anterior, é possível computar o ganho de cerca de 1,93 horas de produção a partir do modelo inicial. Os resultados podem ser observados na Tabela 5.26.

Tabela 5.26 - Modelo de programação atual da fábrica considerando aproveitamento de setups  
(baixa)

Demanda dia						
Dia	1	2	3	4	5	Total Fim
Peças	46383	33228	65238	52220	46050	243119
Minutos	1660,7	964,5	2485,4	1592,4	1527,9	8230,9
Setup qts	4	3	3	3	3	16
Setup min	120	90	90	90	90	480
Total dia min	1781	1055	2575	1682	1618	8711
Capacidade	1742	1742	1742	1742	1742	8710
Atraso	39	-	833	-	-	872

Nessa situação, o atraso estimado médio seria de aproximadamente 872 minutos, menor que os 1395 minutos do primeiro método, e o atraso em peças seria de 17908, 14% também menor em comparação ao caso anterior. O problema maior consiste, então, na variação da demanda, o que gera os atrasos desnecessários. Essa variação pode ser constatada nos dias 2 e 3. No dia 3, a demanda em minutos é de 2575, enquanto que, no dia 2, a demanda é de 1781 minutos. Já a capacidade média necessária fica em 1742 minutos. Esse problema também é conhecido como desbalanceamento da programação (LUIZ, 2012).

Para facilitar o entendimento, foi realizado um gráfico de demanda *versus* capacidade na Figura 5.10, na qual a linha laranja mostra a capacidade em minutos. Assim como nos outros gráficos da dissertação, o eixo *x* representa o tempo em dias. Na forma gráfica, é interessante observar os picos formados entre os dias 2 e 3 de produção, que geram uma amplitude de 1025 minutos.




Figura 5.10 - Comparação demanda x capacidade

Com essa variação, fica claro que, se a demanda fosse seguida à risca, haveria problemas de capacidade a partir do dia 3, devido ao dia 2 ficar subutilizado. Novamente, a empresa pode sofrer prejuízos mesmo a demanda estando mais baixa. Como isso também acontece nos casos de produção alta e média, é possível concluir que é de suma importância estudar sobre os modelos de programação, como este que foi feito nessa dissertação. Uma das soluções existentes, é portanto, utilizar o modelo capacitado criado.

Para se testar esse modelo, então, foi definida uma capacidade de 1797 minutos por dia, para que não haja problema de falta de tempo e a otimização não seja encerrada por essa restrição. O total para 5 dias é de 8985 minutos de capacidade. Esse valor foi definido pois, ao se utilizarem outros valores para a demanda, o sistema utiliza folgas altas, que alteram a capacidade de um dia em mais de 500 minutos, tornando assim o sistema inviável para utilização industrial, embora ele otimize, de forma correta, de acordo com a modelagem. Apesar da quantidade ser de 8985 para os 5 dias, comparando-se com o modelo utilizado atualmente pela empresa, já ocorre uma diferença de 295 minutos, ou seja, 3,2%, que já pode ser considerado como um ganho inicial do modelo. Esse primeiro teste realizado com os dados para a demanda baixa e com o modelo criado considerou os pesos dos atrasos dos produtos como sendo iguais para todos. Dessa forma, os produtos com maiores tempos de produção estão mais sujeitos a atrasar, porque a otimização leva em consideração apenas o atraso em peças e não em tempo. Os custos dos atrasos para produtos pode ser observada em (5.12) e custo dos atrasos por dia pode ser visto em (5.13).

$$Custo = [ 1 1 1 1 1 ] \quad (5.12)$$

$$Custo \text{ atraso peça} = [ 1 1 1 1 1 1 1 1 1 1 1 1 ] \quad (5.13)$$

Como a capacidade mínima foi respeitada, todos os itens foram fabricados no tempo proposto. Os períodos de fabricação das peças podem ser observados na Tabela 5.27. Diferentemente das tabelas dos casos com produção alta e média, essa tabela aparece com vários espaços vazios. Isso porque a produção e o número de *setups* é bem menor.

Tabela 5.27 - Valores de produção por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	36080	0	24234	866	17200
	2	0	0	0	6693	1190
	3	0	0	99	2	1
	4	6800	0	0	0	0
	5	0	0	0	0	0
	6	1000	26976	0	10	14690
	7	0	0	1150	0	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	600	0	0	0	0
	12	19313	46826	611	0	0
	13	0	0	25920	0	12960

Como previsto no começo do capítulo, a única peça atrasada foi a do tipo 2, que tem o maior tempo de produção das produzidas nessa série. Ela sofreu atraso de 1853 peças no período 1, de 2593 no período 2 e de 6693 no período 3. Novamente, conclui-se que o modelo opera de forma correta e respeita a função objetivo, minimizando assim o número de peças atrasadas e não o tempo. Vale lembrar que a peça 2 é quase 10 vezes mais lenta de produzir que a 1, que possui um tempo de produção considerado padrão.

Apesar de ocorrer um atraso nas peças citadas, a redução das perdas cai de 20804 para 11139 no modelo com otimização. Além disso, é visível que o atraso da peça do tipo 2 vai se acumulando nos períodos 2, 3, 4 e é diluído nos períodos 4 e 5.

Ao se comparar o número de peças atrasadas do modelo original com o modelo proposto nesse teste, é possível relatar grande melhora. No modelo original, o atraso é de 20804 peças, enquanto que no modelo otimizado ele é de 11139 peças, o que, em termos percentuais,



representa uma melhora de 53%. O atraso vai se acumulando na peça do tipo 2 até o período 4 e é diluído nos períodos 4 e 5.

Outro ponto interessante a ser levantado sobre esse teste é que ele programou exatamente o número de peças proposto, ao contrário dos casos com demanda média. Isso ocorre porque, apesar de existir um *gap* na solução de 0.001, o resultado ideal pode ser encontrado. Mesmo com todas as peças produzidas, ainda ocorreria uma sobra de tempo de 174 minutos. Apesar dessa sobra, caso fossem reduzidos esses minutos na capacidade inicial, o uso de folgas poderia causar resultados indesejáveis e que gerassem demanda muito desniveladas, como visto no modelo atual da empresa.

O nivelamento pode ser visto na Figura 5.11, na qual a demanda, em laranja, apresenta-se sempre muito próxima à capacidade. Os dias que possuem alguns minutos a mais que a capacidade utilizam o conceito de folgas na produção para otimizar o atraso.




Figura 5.11 - Comparação demanda x capacidade baixa

Por último, foram contabilizados os ganhos de forma financeira. Para isso, foram somados os ganhos com hora-homem, hora-máquina e fretes aéreos utilizados<sup>14</sup>. Novamente são calculados os fretes-extra como sendo a 10% ou 40% dos atrasos, padronizando assim a análise. Esses resultados podem ser observados na Tabela 5.28.

<sup>14</sup> Custos: Hora-homem : R\$ 17,96, Hora-máquina : R\$ 20,00, Frete-extra: R\$ 0,16 a mais por peça enviada

Tabela 5.28 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/home m	Total economizado (min)	Economia semana	Economia ano
Homem hora	17,96	0,3	464	139,2	7516,8
Hora-máquina	20	0,33	464	153,12	8268,5
Total Insumo	37,96	0,63	928	292,32	15785,3
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economia ano
Custo frete extra (10%)	0,16	0,1	6769	108,304	5631,8
Custo frete extra (40%)	0,16	0,4	6769	433,216	22527,2
Total frete com frete 10%				400,624	20832,4
Total frete com frete 40%				725,536	37727,9

Os resultados dessa Tabela 5.28 permitem concluir que com o programa é possível alcançar uma redução de R\$ 292,00 por semana considerando hora-homem e máquina, menor que nas outras demandas analisadas. Isso deve-se, principalmente, a uma menor redução no atraso. No caso da demanda média, por exemplo, a redução chegou a 100%, no caso atual só 53%. Outra razão para esse resultado deve-se ao número de peças fabricadas, que é menor, o que torna os resultados absolutos menores e mais difíceis de serem obtidos. Mesmo assim, em um ano a economia chega a R\$ 37727,90, considerando o pior caso dos fretes-extra. Além disso, custos marginais e outros tipos de despesas não são incluídos nessa análise por não serem mensuráveis ou simplesmente porque o pesquisador não possui acesso ao banco de dados da empresa estudada.

Tal qual o ocorrido na alta demanda e previsto no começo da seção, os tipos de peça com tempos altos de produção sofreram os maiores atrasos. Para sanar esse problema foi proposta, então, a modelagem com alteração no custo peça a peça, melhorando a realidade do modelo. Com isso, o sistema de tomada de decisão do algoritmo foi influenciado a produzir primeiro as peças mais lentas. Como pode ser visto na Tabela 5.7 as peças do tipo 2 e 3 representam os maiores custos. Isso é lógico, porque elas são mais demoradas para se produzir, consumindo assim mais recursos. Os novos vetores de custo podem ser observados nas equações (5.14) e (5.15).

$$Custo = [1 \ 1 \ 1 \ 1 \ 1] \quad (5.14)$$

$$\text{Custo atraso peça} = [1\ 7\ 7\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1] \quad (5.15)$$

Esse segundo modelo testado também conseguiu programar todos os itens para a fabricação, podendo o programa ser visto na Tabela 5.29. Nesse programa é possível notar com maior clareza as peças avulsas produzidas dentro do erro de  $1 \times 10^{-3}$  do modelo. Nota-se, ainda, que, nesse caso, todos os períodos devem produzir a peça do tipo 1, diferentemente do que acontece no primeiro teste da demanda baixa. Isso indica uma melhor distribuição das demandas. Para esse novo teste foi utilizada uma capacidade de 1796 minutos por dia.

Tabela 5.29 - Valores de produção por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	9303	26775	8638	29810	3854
	2	5963	0	0	0	1921
	3	0	0	0	1	0
	4	0	6799	1	0	0
	5	0	0	0	0	0
	6	1000	12937	14082	0	14657
	7	0	0	0	1150	0
	8	0	0	0	0	0
	9	0	0	0	0	7
	10	0	0	0	0	0
	11	600	0	0	0	0
	12	0	19600	47150	0	0
	13	0	0	0	25920	12960

Para esse teste, no entanto, o resultado foi de 33.627 peças atrasadas. Dessa forma, foi o primeiro dos testes apresentou piora em relação ao número de peças atrasadas se comparado com os números obtidos com o método utilizado pela empresa. Essa verificação pode ser realizada através da Tabela 5.30.

É possível notar a diferença nos tipos de peças atrasadas entre o primeiro modelo testado, que possui custo igual para todas as peças, e o segundo modelo testado com o custo diferenciado para as peças do tipo 2. Como o atraso foi recalculado para ser igual a 7 para esses tipos de peça, o programa preferiu produzi-las no período proposto, havendo atrasos somente nos períodos 3 e 4. Esse atraso sai de 11.139 para 1.460. O efeito colateral dessa produção do item 2 é que outros itens de produção mais rápida são deixados em segundo plano. Como já comentado anteriormente, ocorre atraso de 33.627 peças do tipo 1, 12 e 13. Essas peças

possuem tempo de fabricação baixo e contribuem para um atraso alto. Comparando-se com o modelo utilizado atualmente pela empresa, é possível notar que houve uma piora. O atraso em número de peças saiu de 11.139 peças para 35.091 peças, que, em termos percentuais, é três vezes pior.

Tabela 5.30 - Atraso em cada período por tipo

		Atraso (dias)				
		1	2	3	4	5
Tipo do produto	1	18177	2	0	0	0
	2	0	0	730	730	0
	3	0	0	0	0	0
	4	6800	1	0	0	0
	5	0	0	0	0	0
	6	0	1	0	0	0
	7	0	0	0	0	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	0	0	0
	12	8650	0	0	0	0
	13	0	0	0	0	0

Com relação ao tempo, é possível notar que o atraso do segundo teste em tempo de produção é de 1.276 minutos, enquanto que no modelo utilizado pela empresa é de 872. Igualmente, ele pode ser justificado pela priorização das peças 2 e 3 na fabricação. Para se ter uma comparação, a primeira otimização realizada gera um atraso 2706 minutos. Isso prova que o modelo de produção privilegia o menor atraso em peças, mesmo quando o custo do atraso é variado. Tal objetivo pode ser visto na função objetivo na Equação (5.3), a qual valida novamente a modelagem.

Ademais, o tempo total gasto é menor que no primeiro teste para demanda baixa, totalizando uma sobra de 174 minutos do total de 8900 programados, ou seja, existe capacidade para que a demanda seja feita sem maiores contratempos. Outra análise interessante que deve ser feita diz respeito à melhora absoluta do tempo estimado de produção, que é de 3,2%, seguindo, aproximadamente, o patamar alcançado pelos casos estudados com a demanda média.

Apesar de haver ocorrido uma piora no atraso em número de peças, o gráfico “demanda x capacidade” manteve-se nivelado, o que ajuda a gerar uma programação mais coerente. Essa informação foi extraída da Figura 5.12.




Figura 5.12 - Comparação de demanda x capacidade baixa

Na parte financeira também pode ser notada a piora nos resultados em comparação com o modelo da empresa. Essas informações estão na Tabela 5.31.

Assim como no primeiro teste, essa melhora no atraso e no tempo de produção pode ser contabilizada financeiramente. Para isso, pode-se adicionar a hora homem com a hora máquina economizada. Além disso, a redução na necessidade de frete aéreo também pode ser calculada. Dessa forma, foram realizadas as hipótese para 10% e 40% de frete-extra para os itens atrasados.

Tabela 5.31 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/home m	Total economizado (min)	Economia semana	Economi a ano
Homem hora	17,96	0,3	515	154,5	8343,0
Hora-máquina	20	0,33	515	169,95	9177,3
Total Insumo	37,96	0,63	1030	324,45	17520,3
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economi a ano
Custo frete extra (10%)	0,16	0,1	-17183	-274,928	-14296,3
Custo frete extra (40%)	0,16	0,4	-17183	-1099,712	-57185,0
Total frete com frete 10%				49,522	2575,1
Total frete com frete 40%				-775,262	-40313,6

A Tabela 5.31 demonstra que a redução de custo fica, basicamente, igual ao do modelo com custos fixos, primeiro modelo de otimização, ao se analisar a questão de economia em

hora-máquina e hora-homem, reduzindo em torno de R\$ 17520,0. Porém, os custos com frete extra tornam essa opção menos atraente se comparada novamente, pois a redução de custo da empresa vira prejuízo. No caso, para apenas 10% do atraso contando como frete extra aéreo, a economia ocorre uma perda de R\$ -14296,3. Já para o caso crítico, no qual 40% do atraso em peças é enviado de frete extra aéreo, a economia para a empresa chega a R\$ -57185,00 por ano. Isso porque o número de peças atrasadas aumenta bastante em comparação com o modelo atualmente utilizado pela empresa. Como comparação, o modelo 1, com custos iguais para as peças, apresentou uma redução em termos absolutos de R\$ 15785,00.

Como esse modelo<sup>15</sup> apresentou grandes atrasos, e uma piora no lucro da empresa, ele foi testado novamente, dessa vez com uma capacidade diferente. Essa capacidade foi de 1820 minutos por dia e teve como objetivo observar se ocorreria alguma diferença significativa no atraso em número de peças.

Assim como o primeiro teste e o segundo teste realizados, o terceiro teste novamente ocorreu sem problemas. Os períodos de fabricação de cada peça podem ser vistos na Tabela 5.32. Essa tabela mostra que todas as peças necessárias foram produzidas dentro do tempo esperado.

Tabela 5.32 - Valores de produção por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	8422	27568	9756	15396	17151
	2	6160	0	0	0	1723
	3	0	0	0	1	0
	4	0	6800	0	0	0
	5	0	0	0	0	0
	6	999	12940	14038	593	14106
	7	0	0	1150	8	0
	8	0	0	0	4	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	600	0	1	1	0
	12	1	19599	47150	1	0
	13	0	0	0	25920	12960

<sup>15</sup> Segundo modelo de otimização testado com a demanda baixa

No entanto, assim como no teste anterior, o atraso acumulado foi maior que no método utilizado pela empresa e chegou a 35575 peças no total, podendo ser visto na Tabela 5.33.

Tabela 5.33 - Atraso em cada período por tipo

		Atraso (dias)				
		1	2	3	4	5
Tipo do produto	1	19058	0	0	0	0
	2	0	0	533	533	0
	3	0	0	0	0	0
	4	6800	0	0	0	0
	5	0	0	0	0	0
	6	1	0	0	0	0
	7	0	0	0	0	0
	8	0	0	0	0	0
	9	0	0	0	0	0
	10	0	0	0	0	0
	11	0	0	0	0	0
	12	8650	0	0	0	0
	13	0	0	0	0	0

Assim como no ocorrido com o teste com 1.796 minutos por dia, a tabela de produção por peças 5.32 permite concluir que ocorre um esforço do programa da otimização em produzir as peças do tipo 2 nos primeiros períodos. Isso ocorre porque o atraso dessa peça é colocado como 7 ao invés de 1, o que aumenta seu peso, fato que se mostra interessante pois, apesar de a demanda ser de apenas 1.853 no primeiro dia, são produzidas 6.160, de modo a aproveitar o *setup* e evitar atrasos nos turnos posteriores. O efeito colateral é o atraso das outras peças. No entanto, nem todas as peças do tipo 2 necessárias para o período de cinco dias são produzidas no dia 1 e, por isso, ocorrem atrasos nos períodos 3 e 4, totalizando 1.066 peças. É possível observar ainda, que, mais de 90% do atraso, que decorre dos tipos de peça 1 e 12, ocorre no primeiro período.

Comparando-se o atraso gerado por esse modelo, que é de 35.575, com o do modelo com custos iguais a 1, no qual o número de peças atrasada foi de 11.13, é possível notar uma grande piora. No entanto, se comparado ao modelo com 35091 peças, o atraso é praticamente o mesmo, apresentando um aumento de 484 peças.

Outra vez, apesar do resultado ruim com o atraso a demanda, esta se manteve nivelada. Tal nivelamento, representado em laranja, pode ser visto na Figura 5.13 e apresenta uma reta diferente da observada na Figura 5-12. Isso mostra que, apesar do atrasos serem parecidos a otimização, levou a resultados diferentes. Essa diferença é vista nos dias 3 e 4 de produção, pois

na Figura 5.12 o dia mais ocioso de produção é o quinto enquanto que na 5.13 é no quarto. Em situações reais, o mais comum é realizar toda a produção o quanto antes e deixar o ultimo dia ocioso, como o visto na Figura 5.12.




Figura 5.13 - Comparação de demanda x capacidade baixa

Com relação ao tempo de produção, também não houve melhora uma vez o atraso foi de 1204 minutos nesse modelo, enquanto que, no modelo testado com capacidade menor (1796 minutos), foi de 1200. A diferença no tempo de produção permanece parecida, com o modelo com mais capacidade (1820) apresentando apenas 30 minutos a mais, ou seja, um *setup*. Essas informações provam a ineficácia em se aumentar a capacidade para esse modelo com diferenças nos pesos dos produtos

Como as diferenças em número de peças atrasadas e total de tempo consumido são baixos, pode-se concluir, observando a Tabela 5.31, que os valores das perdas seriam parecidos. Portanto, o aumento da capacidade não obteve os resultados esperados e prova, mais uma vez, que, para esse caso, o modelo é ineficiente em otimizar o atraso em número de peças em comparação com o modelo original não capacitado.

O quarto e último teste com o conjunto de dados para demanda baixa foi realizado variando-se, além do custo por peça, o custo do atraso por período. Esse teste foi realizado para comparar seu comportamento com relação a essa variação na demanda e de tentar melhorar os ganhos para a baixa demanda. A diferença desse teste reside no fato de que com os atrasos dos períodos aumentando gradativamente o sistema do modelo seja forçado a produzir mais nos primeiros dias para evitar arcar com custos maiores no fim. Essa alteração no atraso por dia visou direcionar o programa a aproveitar capacidades restantes nos primeiros dias e deixar os



últimos com o maior tempo restante possível, tentando reproduzir a realidade mais fielmente. A equação que mostra esse a mudança do custo do atraso pode ser vista em (5.16) e (5.17).

$$Custo = [ 1 \ 2 \ 3 \ 4 \ 5] \quad (5.16)$$

$$Custo \ atraso \ peça = [ 1 \ 7 \ 7 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1] \quad (5.17)$$

Mais uma vez, o programa funcionou corretamente e programou as peças necessárias ainda que pequenas quantidades de peças tenham sido fabricadas em períodos não necessários devido ao erro que já era esperado. Para realização foi utilizado uma capacidade de 1796 minutos por período.

Tabela 5.34 - Valores de produção por período e tipo

		Produção (dias)				
		1	2	3	4	5
Tipo do produto	1	31737	29450	0	0	17193
	2	0	0	0	6695	1194
	3	0	0	2	0	3
	4	6800	0	0	0	0
	5	0	0	0	0	0
	6	1000	26975	1	5	14695
	7	1150	0	0	0	0
	8	0	0	0	0	0
	9	0	0	0	0	6
	10	0	0	0	0	0
	11	600	0	0	0	0
	12	19599	1	47150	0	0
	13	0	9880	16040	0	12960

Em comparação com o modelo utilizado pela empresa, o atraso no número de peças cai de 41.184 para 11.139 peças, ou seja, igual ao modelo com os custos iguais a 1 sendo, portanto, conseguida uma melhora de 35% no atraso. Tal acontecimento mostra que, para os dados com demanda baixa, a variação de custos de produtos e datas gera os mesmos resultados que a não variação. Mesmo assim, esse fato prova, novamente, a eficácia do modelo. Além disso, como no primeiro caso testado para demanda baixa, os atrasos ocorrem somente para a peça dois, mesmo o sistema sabendo que o custo aumenta a partir do dia 2. Esses atrasos são de 1853 peças no período 1, 2593 no período 2 e 6693 no período 3.

Como visto no primeiro caso estudado para a demanda alta, houve uma redução significativa de minutos utilizados. Esses minutos configuram uma melhora no tempo de *setup*. No entanto, o tempo de atraso foi de 2706 minutos, igual ao modelo no qual os custos são iguais a 1. Ainda, comparando-se com o modelo não capacitado, o atraso continua maior, pois nele o atraso é de 872 minutos. Isso prova, mais uma vez, que o modelo, embora tenha reduzido o atraso em número de peças, não diminuiu o atraso em tempo. Com relação ao tempo total programado, ocorre uma melhora de 200 minutos, saindo de um total de 9.280 para 8.980. Além disso, dos 8.980 minutos programados ocorre uma sobra de 274 minutos, ou seja, existe capacidade para que a demanda seja feita sem maiores contratempos.

Esse teste também mostrou que a produção ficou nivelada entre os períodos, como pode ser visto na Figura 5.14, provando mais uma vez a importância de se criar um sistema capacitado para programar a fábrica.




Figura 5.14 - Comparação de demanda x capacidade - baixa

Como nos outros testes, a característica da folga foi programada para evitar a perda de tempo nos fins dos períodos, problema recorrente em todas as séries de dados. Com relação ao tempo de atraso, ele foi de 2706 minutos, igual ao modelo no qual os custos são iguais a 1, que possui um atraso de 2706 minutos. Ainda, comparando-se com o modelo não capacitado, o atraso continua maior, pois nele o atraso é de 872 minutos.

Financeiramente, os resultados são também muito parecidos com o modelo em que os somente os custos das peças variam, o anterior. Eles somente não são idênticos porque os valores utilizados para capacidade variam ligeiramente de um para o outro, mudando o valor

das perdas em dinheiro. A tradução dos resultados para o campo das finanças pode ser visto na Tabela 5.35.

Tabela 5.35 - Ganhos computados com o uso do programa de otimização

Ganho estimado semana e ano					
	Custo hora	Minuto/home m	Total economizado (min)	Economia semana	Economi a ano
Homem hora	17,96	0,3	574	172,2	9298,8
Hora-máquina	20	0,33	574	189,42	10228,7
Total Insumo	37,96	0,63	1148	361,62	19527,5
	Custo peça	% frete aéreo	Total economizado (peças)	Economia semana	Economi a ano
Custo frete extra (10%)	0,16	0,1	-17183	-274,928	-14296,3
Custo frete extra (40%)	0,16	0,4	-17183	-1099,712	-57185,0
Total frete com frete 10%				86,692	4508,0
Total frete com frete 40%				-738,092	-38380,8

Nesse caso, o lucro vira prejuízo. Apesar de o custo semanal da operação cair cerca de R\$ 361,62 por semana, com o aumento do atraso o frete extra aéreo aumenta o prejuízo da operação, o que gera uma perda de R\$ -14.296,3, se utilizado 10% do total do atraso. Já para o caso no qual 40% do atraso em peças é enviado de frete extra aéreo, a economia para a empresa chega a R\$ -57.185,00 por ano. Isso porque o número de peças atrasadas aumenta bastante em comparação com o modelo atualmente utilizado pela empresa. Como comparação, o modelo 1, com custos iguais para as peças, apresentou uma redução em termos absolutos de R\$ 15.785,00, provando a afirmação feita no início desse parágrafo.

Em resumo, A Tabela 5.36 mostra uma síntese dos resultados obtidos na demanda alta, enquanto que as Tabelas 5.37 e Tabela 5.38 mostram os resultados das demandas média e baixa respectivamente. É possível concluir, analisando essas tabelas, que a economia para a fábrica com a utilização desse modelo se dá em praticamente todos os casos analisados, exceto nos modelos para demanda baixa que variam os custos de peças. Isso deve-se, principalmente, ao fato de haver menor possibilidade de otimizar esses dados devido à grande produção de peças do tipo 2 e um tempo menor para fabricação.

Tabela 5.36 - Síntese dos resultados obtidos na demanda alta

Demanda alta				
Tipo do modelo	Tempo economizado semana(min)	Redução do atraso semana (pçs)	Economia 10% frete ano (R\$)	Economia 40% frete ano(R\$)
Custo das peças idêntico	1075	25771	R\$	R\$
Custo atraso por período idêntico			56.811,40	121.135,80
Custo das peças variando	1046	25301	R\$	R\$
Custo atraso por período idêntico			55.317,40	118.468,70
Custo das peças variando	976	24076	R\$	R\$
Custo atraso c/ período variando			52.005,00	112.098,70

Tabela 5.37 - Síntese dos resultados obtidos na demanda média

Demanda média				
Tipo do modelo	Tempo economizado semana(min)	Redução do atraso semana (pçs)	Economia 10% frete ano (R\$)	Economia 40% frete ano(R\$)
Custo das peças idêntico	622	37618	R\$	R\$
Custo atraso por período idêntico			51.674,90	145.569,40
Custo das peças variando	601	41184	R\$	R\$
Custo atraso por período idêntico			53.953,80	156.749,10
Custo das peças variando	594	21642	R\$	R\$
Custo atraso c/ período variando			37.315,80	90.885,00

Tabela 5.38 - Síntese dos resultados obtidos na demanda baixa

Demanda baixa				
Tipo do modelo	Tempo economizado semana(min)	Redução do atraso semana (pçs)	Economia 10% frete ano (R\$)	Economia 40% frete ano(R\$)
Custo das peças idêntico	464	6769	R\$	R\$
Custo atraso por período idêntico			20.832,40	37.727,90
Custo das peças variando	515	-17183	R\$	-R\$
Custo atraso por período idêntico			2.575,10	40.313,00
Custo das peças variando	574	-17183	R\$	-R\$
Custo atraso por período variando			4.508,00	38.380,80

## 6 CONCLUSÃO

A competitividade entre as empresas vem aumentando com o passar dos anos, por isso a melhoria da produtividade vem se tornando cada vez mais uma necessidade para diversos setores, desde fábricas de alimentos até a indústria automobilística. Para melhorar sua produtividade e se manter no mercado, as empresas visam otimizar a eficiência de diversas áreas, entre elas a área de planejamento e controle de produção, que inclui a programação.

Por causa dessa importância para a área industrial, o presente projeto visou estudar um modo de melhorar a programação de um setor de retíficas e reduzir o atraso em peças de uma empresa de autopeças no sul de Minas Gerais. Foram obtidos dados do MRP, sem restrição de capacidade para as máquinas da empresa, para serem testados com um novo modelo de *lot sizing*, do tipo CLSP, ou seja, com restrição de capacidade.

Com capacidade utilizada como restrição, e conseqüente redução do atraso em peças, houve uma redução de custos com mão de obra direta, maquinário e fretes-extra para os clientes.

Os testes com o modelo foram realizados com três tipos de demanda, alta, média e baixa. Foi possível observar que, nos três tipos de demanda analisados, o modelo apresentou ganhos consideráveis pela empresa nos quesitos apresentados no parágrafo anterior. No caso da demanda média, o modelo conseguiu reduzir o atraso em peças em 100% e apresentou ganhos anuais em mais de R\$ 100.000,00.

Além dos ganhos observados nos resultados, é possível observar que o uso de folgas entre os períodos de produção no modelo permitiu que ele tivesse uma maior flexibilidade se comparado com os modelos CLSP tradicionais encontrados na literatura, constituindo-se assim como uma versão modificada do CLSP para a literatura.

Outro ponto importante observado no trabalho diz respeito aos dados utilizados, que estão disponíveis no anexo 1 do trabalho, podendo ser utilizados em trabalhos futuros.

Com relação à revisão bibliográfica, o trabalho procurou abranger os tipos mais comuns de modelos de *lot sizing*, referenciando tanto trabalhos clássicos como trabalhos mais atuais, para que outros pesquisadores possam utilizá-la como ponto de partida para pesquisas mais profundas.

O método utilizado também foi descrito passo-a-passo, permitindo um melhor entendimento da condução da pesquisa, mitigando possíveis dúvidas quanto à modelagem, obtenção dos dados e solução pelo modelo criado, fortalecendo dessa forma o uso do método na pesquisa em engenharia de produção.

Portanto, o trabalho atendeu às expectativas iniciais e pode ajudar a reduzir o atraso em peças, o que, para a empresa, significa reduzir os custos inerentes aos setups, custo-máquina, custo-peça e fretes extras. Além disso, as outras partes da dissertação, como método e revisão bibliográfica, podem ser utilizadas por outros pesquisadores para enriquecerem seus trabalhos. Por isso, devido aos resultados positivos obtidos, seria interessante continuar a pesquisa através de estudos para a expansão do modelo de uma máquina para múltiplas máquinas, da mudança de um nível para mais níveis, a adição de refugo e retrabalho ao cálculo de capacidade, além de um sistema para encontrar a capacidade ótima automaticamente.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

ALLAHVERDI, A.; NG, C.T.; CHENG, T.C.E.; KOVALYOV, M. Y. A survey of scheduling problems with setup times or costs. **European Journal of Operational Research**, v.187, p.985–1032, 2008.

ARAÚJO, J. S.; FUCHIGAMI, H. Y. Modelagem matemática do problema de sequenciamento da produção com *setup* dependente e filosofia *just-in-time*. **E-xacta**, v.6, p.165-175, 2013.

BELFIORE, P.; FÁVARO L. P. **Pesquisa Operacional para cursos de engenharia**. Primeira Edição. São Paulo: Elsevier. 2013.

BELVAUX, G.; WOLSEY, L. Modelling practical lot-sizing problems as mixed integer programs. **CORE Discussion Papers** ; 2000/9, 2000.

BERTRAND, J. W. M.; FRANSOO, J. C. Modelling and simulation: operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 241-264, 2002.

BIERWIRTH, C.; MATTFELD D. C. Production scheduling and rescheduling with genetic algorithms. **Evolutionary computation**, v. 7, p. 1-17, 1999.

BRAGA C. H.; ROSSI J. W. L.A. Mensuração da eficiência produtiva na indústria brasileira. **Management Science**. IPEA. Rio de Janeiro, Brasil. 1985.

A indústria em números. Confederação Nacional da Indústria (Brasil), Brasília, Agosto. 2016. Disponível em: < <http://www.portaldaindustria.com.br/estatisticas>>. Acesso em: 06 out. 2016.  
Anuário da Indústria automobilística brasileira. ANFAVEA (Brasil), São Paulo, Agosto. 2016. Disponível em: < <http://www.anfavea.com.br/anuario.html> >. Acesso em: 07 out. 2016  
ANFAVEA (2016)

BUSCHKÜHL, L.; SAHLING, F.; HELBER, S.; TEMPELMEIER, H. Dynamic capacitated lot-sizing problems: a classification and review of solution approaches. **OR Spektrum**, v. 32, p. 231-261, 2010

CASTRO, C.A. **Tamanhos de lotes capacitados com preparação de máquina em sistemas produtivos ininterruptos**. Dissertação (Mestrado em engenharia de produção) – Programa de pós graduação em Engenharia de Produção, UFMG, Belo Horizonte. 2007.

CARVALHO, D. M.; NASCIMENTO, M. C. V. Lagrangian heuristics for the capacitated multi-plant lot sizing problem with multiple periods and items. **Computers & Operations Research**, v.71, n.1, p. 137-148,2016.

CHENG, J.; KARUNO, Y.; KISE, H.; A shifting bottleneck approach for a parallel-machine flowshop scheduling problem. **Journal of the Operations Research Society of Japan**, v.44, p.140-156, 2001.

CHUNG, C. A. **Simulation modeling handbook: a practical approach**. Florida: CRC Press, 2004.

CORRÊA, H.L.; CORRÊA, C.A. **Administração de produção e operações: manufatura e serviços: uma abordagem estratégica**. São Paulo: EditoraAtlas, 2006.

DREXL, A.; KIMMS, A. Lot sizing and scheduling - Survey and extensions. **European Journal of Operational Research**, v. 99, p. 221-235, 1997.

FLOUDAS, C. A.; LIN, XIAXONIA. **Mixed Integer Linear Programming in Process Scheduling: Modeling, Algorithms, and Applications**. Annals of Operations Research, v. 139, p.131-162, 2005.

FOO, Y. P. S.; TAKEJUJI, Y. Integer Linear Programming Neural Networks for Job-Shop Scheduling. In : IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1988, San Diego, **IEEEExplore**. San diego: IEEE, 1988

GANTT, H.L. **Work, Wages, and Profits**, Nova York: Hive Publishing Company, 1973.

GUIMARAES, I. F. G.; SOUZA, M. C.; YALAOUI, F. O problema de sequenciamento da produção em um ambiente flowshop com linhas semiparalelas e operação de sincronização final. In: XXXV ENCONTRO NACIONAL DE ENGENHARIA DE PRODUCAO, 2015; Fortaleza, 2015.

GRAVES, S. C. A review of production scheduling. **Operations research**, v. 29, p.646-675, 1981.

HAASE, K. Lotsizing and scheduling for production planning. **Lecture notes in economics and mathematical systems**, v.408, 1994.

HAASE, K.; KIMMS, A. Lot Sizing and Scheduling with Sequence Dependent Setup Costs and Times and Efficient Rescheduling Opportunities. **Or spektrum**, n. 393, 1997

HARRIS F. W. How many parts to make at once. **Factory, The Magazine of Management**, v.2 (10): p.135-136, 1913

HANSSMAN, F. **Operations Research in Productions and Inventory**. John Wiley & Sons, 1962.

HELBER, S. SAHLING, F. SCHIMMELPFENG, K. Dynamic capacitated lot sizing with random demand and dynamic safety stocks. **OR Spektrum**. v. 35. Springer-Verlag, 2012. p. 75-105.

HERRMANN, J.W. A history of production scheduling. In: **Handbook of production scheduling**. Herrmann. J.W. (Org.) United States: Springer US, 2006. p. 1-23

JANS, R.; DEGRAEVE, Z. Modeling Industrial Lot Sizing Problems: A Review. **International Journal of Production Research**, v. 46, p.1619-1643, 2008.

JUNIOR, D. R. G.; JESUS, E. Sequenciamento de produção com restrição na ordem de precedência. **GEINTEC**, v.2, p.274-284, 2012.



KATOK, E.; OTT, D. Using Mixed-Integer Programming to Reduce Label Changes in the Coors Aluminum Can Plant. **Interfaces**. Maryland, USA, v. 30, n. 2, p.1-12. 2000.

KARIMI, B.; GHOMI, S.M.T.F.; Wilson, J.M. The capacitated lot sizing problem: a review of models and algorithms. **Omega**, v.31, p.365–378, 2003.

KIMMS. A. Multi-level, single-machine lot sizing and scheduling (with initial inventory). **European Journal of Operational Research**, v. 89, n.1, p. 86-99, 1996

KRAJEWIWSKI, L.J.; RITZMAN, L.P. **Operations Management Strategy and Analysis**. Addison-Wesley Publishing Company, 1993.

LAND, A. H.; DOIG A. G. "An automatic method of solving discrete programming problems". **Econometrica**. 28 (3). pp. 497–520.

LIAW, C. F.; LIN, Y. K.; CHENG, C.Y.; CHEN, M. Scheduling unrelated parallel machines to minimize total weighted tardiness. **Computers & Operations Research**, v. 30, p. 1777-1789, 2003

LOBO, B. A.; KLABJAN, D.; CARRAVILLA, M. A.; OLIVEIRA J. F. Single Machine Multi-product Capacitated Lotsizing with Sequence-dependent Setups. **International Journal of Production Research**, v.45, p.4873-4894, 2007.

LUIZ, R. M. **Programação de produção levando em conta máquinas em paralelo e set-up dependente da sequência de produção**. Dissertação (Mestrado em engenharia) – Programa de pós graduação em Engenharia Mecânica e de Materiais, Área de concentração Manufatura, UTFPR, Curitiba. 2012.

MARTINS R. A.; MELLO, C. H. P.; TURRIONI, J .B. **Guia para elaboração de monografia e TCC em engenharia de produção**. Primeira Edição. São Paulo: Editora Atlas, 2013.

MADROÑERO, M. D.; MULA, J.; PEIDRO, D. A review of discrete-time optimization models for tactical production planning. **International Journal of Production Research**, v. 52, 2014.  
HAASE, K. Capacitated lot-sizing with sequence dependent setup costs. **OR Spektrum**, v. 18, p. 51-59, 1996.

MARINELLI, F.; NENNI, M. H.; SFORZA, A. Capacitated lot sizing and scheduling with parallel machines and shared buffers: A case study in a packaging company. **Ann Oper Res**, v. 150, p. 177-192, 2007.

MENEZES, A. A. CLARK, A. LOBO, B. A. Capacitated lot-sizing and scheduling with sequence-dependent, period-overlapping and non-triangular setups. **Journal of scheduling**. v. 14, n. 2, p 209-2019.

MESQUITA, M, A.; CASTRO, R. L. Análise das práticas de planejamento e controle da produção em fornecedores da cadeia automotiva brasileira. **Gest. Prod.**, v. 15, n. 1, p. 33-42, 2008.

MITROFF, I.; BETZ, F.; PONDY, L. R.; SAGASTI, F. Managing Science in the Systems Age: Two Schemas for the Study of Science as a whole Systems Phenomenon. **Interfaces**, v. 4, n. 3, p. 46-58, 1974.

MOHAMMADI, M.; MUSA, S. M.; BAHREININEJAD, A. Optimization of mixed integer nonlinear economic lot scheduling problem with multiple setups and shelf life using metaheuristic algorithms. **Advances in Engineering Software**, v.78, p. 41-51, 2014.

POCHET, Y. Mathematical Programming Models and Formulations for Deterministic Production Planning Problems. **Computat. Comb. Optimization**, p. 57–111, 2001.

RAO, M.R. Optimal capacity expansion with inventory. **Operations Research**, v.24 (2), p.291-300, 1976.

RAMEZANIAN, R. MOHAMMAD, S. M. TEIMOURY, E. A mathematical model for integrating lot-sizing and scheduling problem in capacitated flow shop environments. **Intl Journal of Advanced Manufacturing Technology**. v.66, p 347-361, 2012.

ROBINSON, E. **Simulation: the practice of model development and use**. England: John Wiley and Sons Ltd.,2004.

RODAMMER, F. A.; JUNIOR, P. W. A Recent Survey of Production Scheduling. **IEEE transactions on systems, man and cybernetics**, v. 18,p. 841-851, 1988.

SALOMON, M.; KROON, L. G.; KUIK, R.; VAN WASSENHOVE, L.V. Some extensions of the discrete lotsizing and scheduling problem. **Management Science**, v. 37, 1991.

SHIM, S. O.; KIM, Y. D. A branch and bound algorithm for an identical parallel machine scheduling problem with a job splitting property. **Computers & Operations Research**, v. 35, p. 863-875, 2006

SHIM, S. O.; KIM, Y. D. Scheduling on parallel identical machines to minimize total tardiness. **European Journal of Operational Research**, v. 177, p.135–146, 2007

SLACK, N.; CHAMBERS. S.; Johnston, R. **Administração da produção**. Terceira Edição. São Paulo: Editora Atlas. 2009.

SOX, C. R.; JACKSON, P. L.; BOWMAN, A.; MUCKSTADT, J. A. A review of the stochastic lot sizing problem. **Int. J. Production Economics**, v. 62, p. 181-200, 1999

STADTLER, H. Multi-level single machine lot-sizing and scheduling with zero lead times. **European Journal of Operational Research**, v. 209, n.1, p. 241-252, 2011

STADTLER, H. SAHLING, F. A lot-sizing and scheduling model for multi-stage flow lines with zero lead times. **Production, Manufacturing and Logistics**. v. 225, p 404 – 419, 2013.

TAHAR, D. N.; YALAOUI, F.; CHU, C.; AMODEO, L. A linear programming approach for identical parallel machine scheduling with job splitting and sequence-dependent setup times. **Int. J. Production Economics**, v.99, p.63–73, 2006.

TAYLOR, F. W. **Princípios de administração científica**. Oitava edição. São Paulo: Editora Atlas, 2010.

TEMPELMEIER<sup>1</sup>, H. COPIL, K. Capacitated lot sizing with parallel machines, sequence-dependent setups, and a common setup operator. **OR Spektrum**. v 38, n.4, p 819-847, 2015.

TRANSCHEL, S. MINNER, S. KALLRATH, J. LÖHNDORF, N. EBERHARD, U. A hybrid general lot-sizing and scheduling formulation for a production process with a two-stage product structure. **International Journal of Production Research**. v. 49, n. 9, p 2463 – 2480.

TUBINO, D. F. **Planejamento e Controle da Produção: teoria e prática**. 1. Edição. São Paulo: Editora Atlas, 2008.

WAGNER, H. M. An integer linear-programming model for machine scheduling. **Naval Research Logistics**, v. 6, p.131-140, 1959.

WAGNER, H. M. WHITIN, T. M. Dynamic version of the economic lot size model. *Management Science*, 1958.

WOLSEY, L.A. Solving Multi-Item Lot-sizing Problems with MIP Solver Using Classification and Reformulation. **Management Science**. Catonsville,USA , v.48 n. 12. 2002.

## 8 ANEXO

Tabela 8.1 - Valores para a demanda alta

Q	P	T	D
1235	2	1	2
1500	3	1	5
13475	2	1	3
13475	2	1	3
2200	3	1	2
12000	3	1	4
1099	2	1	5
12500	3	1	5
1100	2	1	3
10000	2	1	3
8650	3	1	4
2000	1	1	6
200	0	1	3
2109	3	2	2
10920	0	2	3
5560	0	2	3
11000	0	2	3
13500	2	2	3
12500	3	2	5
13560	3	2	3
8650	3	2	4
13475	2	2	3
5780	0	2	3
2700	2	2	3
1100	3	2	5
4600	0	3	3
6566	0	3	3
1000	2	3	4
8600	0	3	3
8600	0	3	3
4600	0	3	3
1100	2	3	2
2142	2	3	4
11850	2	3	2
8650	3	4	4
12500	3	4	5
15000	0	4	3
2070	3	4	3

15000	0	4	3
12500	3	4	5
5600	3	4	3
6600	2	4	2
12660	2	4	3
3700	3	4	4
13560	3	4	3
11600	2	4	2
2070	3	4	3
8650	3	4	4
800	3	4	3
1100	2	5	4
4500	2	5	4
8600	0	5	3
8600	0	5	3
8600	0	5	3
8600	0	5	3
8600	0	5	3
3000	2	5	3
3000	0	5	3
5150	3	5	2
6400	2	5	2
13500	3	5	4
8650	3	5	4

Tabela 8.2 - Valores para a demanda média

Q	P	T	D
12.500	3	1	5
3.225	3	1	4
2.160	2	1	1
12.938	2	1	3
12.938	2	1	3
12.100	2	1	2
8.600	0	1	3
1.099	2	1	5
850	1	1	7
10.500	2	2	3
12.938	2	2	3
12.000	3	2	4
8.600	0	2	3
1.400	1	2	6

4.070	2	2	4
1.150	2	3	4
8.600	0	3	3
8.600	0	3	3
8.600	0	3	3
3.300	3	3	4
12.500	3	3	5
12.938	2	3	3
3.000	3	3	3
7.700	3	3	3
13.475	2	3	3
8.650	3	3	4
8.600	0	3	3
13.560	3	3	3
2.200	3	3	4
2.250	1	4	6
12.938	2	4	3
14.300	3	4	3
8.650	3	4	4
12.938	2	4	3
2.250	1	4	6
14.300	3	4	3
2.600	2	4	2
13.475	2	4	3
8.650	3	4	4
12.500	3	5	5
13.500	2	5	3
13.500	2	5	3
2.000	1	5	6
702	2	5	4
2.800	2	5	4
3.000	3	5	3
3.800	1	5	6

Tabela 8.3 - Valores para a demanda baixa

Q	P	T	D
8650	3	1	4
1853	1	1	6
1680	0	1	3
8600	0	1	3

8600	0	1	3
8600	0	1	3
6800	2	1	1
1000	2	1	3
600	3	1	3
8650	3	2	4
240	1	2	6
500	1	2	6
8600	0	2	3
12938	2	2	3
2300	3	2	4
1750	1	3	6
2350	1	3	6
8600	0	3	3
12938	2	3	3
1100	2	3	3
13500	3	3	4
11500	3	3	4
13500	3	3	4
8650	3	4	4
8600	0	4	3
7900	0	4	3
1150	2	4	4
12960	3	4	5
12960	3	4	5
1190	1	5	6
8600	0	5	3
8600	0	5	3
1200	2	5	3
13500	2	5	3
12960	3	5	5