

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL**  
**ESCOLA DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO MESTRADO PROFISSIONAL EM**  
**ENGENHARIA DE PRODUÇÃO**

Evandro Burgel

**PROPOSIÇÃO DE UMA ABORDAGEM PARA CLASSIFICAÇÃO, PROJEÇÃO E**  
**CONTROLE DA OBSOLESCÊNCIA DE INVENTÁRIOS APOIADA EM**  
**FERRAMENTAS MULTIVARIADAS**

Porto Alegre

2018

Evandro Burgel

**Proposição de uma abordagem para classificação, projeção e controle da obsolescência de inventários apoiada em ferramentas multivariadas**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Profissional, na área de concentração de Sistemas de Produção.

Orientador: Michel Jose Anzanello, Ph.D.

Porto Alegre

2018

Evandro Burgel

**Proposição de uma abordagem para classificação, projeção e controle da obsolescência de inventários apoiada em ferramentas multivariadas**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Acadêmica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

---

Prof. Michel Jose Anzanello

Orientador PMPEP/UFRGS

---

Prof. Ricardo Augusto Cassel

Coordenador PMPEP/UFRGS

**Banca Examinadora:**

Prof. Alessandro Kahmann

Prof. Guilherme Luz Tortorella

Prof. Ricardo Augusto Cassel

## AGRADECIMENTOS

Expresso meus sinceros agradecimentos a todos que contribuíram, direta ou indiretamente, para que este sonho de vida se tornasse realidade.

À minha família, Simone, Matheus e Maria Eduarda, pelos finais de semana e noites em casa dedicados à pesquisa e redação deste trabalho.

Aos meus pais, Orlando e Teresa, pelos valores transmitidos ao longo da vida, por me mostrarem a importância do estudo para o crescimento pessoal e profissional, e pelo sacrifício e dedicação para que eu pudesse chegar até aqui.

Ao Prof. Michel Jose Anzanello, Ph.D., meu orientador, pelos conhecimentos compartilhados, cobrança, apoio e confiança depositada em mim e no meu trabalho.

Às empresas que deram o suporte e apoio necessários à confecção deste trabalho, apoiaram a implantação do método proposto e tornaram viável a realização dos dois estudos de caso.

Aos professores e colegas do Programa de Pós-Graduação em Engenharia de Produção da UFRGS, pelo conhecimento, apoio e parceria ao longo dos últimos anos.

A UFRGS e à sua Escola de Engenharia, através do Programa de Pós-Graduação em Engenharia de Produção, pela excelência do ensino.

A todos, meu muito obrigado!

Burgel, E. **Proposição de uma abordagem para classificação, projeção e controle da obsolescência de inventários apoiada em ferramentas multivariadas**. 2018. Dissertação (Mestrado em Engenharia) - Universidade Federal do Rio Grande do Sul, Brasil.

## RESUMO

A obsolescência de estoques é um evento recorrente nas organizações, demandando o uso de métodos que identifiquem o inventário excessivo antes dele tornar-se obsoleto. Este artigo propõe um método para classificação, projeção e controle da obsolescência de inventários ao longo do tempo, com o objetivo de reduzir o risco de obsolescência ou deterioração futura. A abordagem proposta possui cinco passos, sendo os quatro primeiros dedicados a identificação dos fatores que contribuem para a obsolescência e/ou deterioração do Inventário, a classificação do estoque em categorias e faixas de idade através da análise discriminante, a seleção de variáveis em contexto de PLS, a modelagem de regressão para projeção da idade do inventário ao longo do tempo e a definição de diretrizes para redução do risco de obsolescência. O quinto passo do método utiliza o conceito do ciclo PDCA buscando a melhoria contínua do processo e dos resultados. Na aplicação em dois estudos de caso em indústrias de bens de consumo, o método previu adequadamente o montante do inventário por faixa de idade e o risco de obsolescência ou deterioração do inventário em um horizonte de seis meses.

**Palavras-chave:** Gestão de estoques; obsolescência; seleção de variáveis; PLS; regressão múltipla.

Burgel, E. **Proposition of an approach for the classification, projection and control of inventory obsolescence supported by multivariate tools.** 2018. Dissertation (Master in Engineering) - Federal University of Rio Grande do Sul, Brazil.

## **ABSTRACT**

Inventory obsolescence is a prominent phenomenon in organizations, requiring the use of methods that identify excessive inventory before it becomes obsolete. This paper proposes a method to classify, forecast and control the obsolescence of inventories over time in order to reduce the risk of future obsolescence or deterioration. The proposed approach has five steps, the first four of which are dedicated to identifying the factors that contribute to the obsolescence and/or deterioration of the Inventory, the classification of the inventory into categories and age ranges through discriminant analysis, the selection of variables in the context of PLS, regression modeling to forecast the age of inventory over time and the definition of guidelines for reducing the risk of obsolescence. The fifth step of the method uses the concept of the PDCA cycle seeking for the continuous improvement of process and results. In the application in two case studies in consumer goods industries, the method predicted the amount of inventory by age range and the risk of obsolescence or deterioration of the inventory over a six-month horizon.

**Keywords:** Stock management; obsolescence; selection of variables; PLS; regression analysis.

## LISTA DE FIGURAS

Figura 1 – Etapas do modelo proposto para seleção de variáveis preditivas no contexto de redução do risco de obsolescência do inventário em empresas fabricantes de bens de consumo que forneçam para grandes redes varejistas .....	47
Figura 2 – Resultados obtidos antes e depois da implantação do método proposto .....	86
Figura 3 – Resultados obtidos antes e depois da implantação do método proposto .....	110
Figura 4 – Ajuste de linha de tendência polinomial nas duas séries temporais .....	111

## LISTA DE QUADROS

Quadro 1 – Classificação das técnicas multivariadas .....	23
Quadro 2 – Propriedades do $R^2$ para modelos de regressão .....	30
Quadro 3 – Técnicas de seleção de variáveis .....	46
Quadro 4 – Dados coletados pelo time multifuncional a cada período (mensal) .....	67
Quadro 5 – Classificação original dos itens no sistema ERP .....	68
Quadro 6 – Classificação dos itens conforme a sua situação no inventário .....	69
Quadro 7 – Resultados da análise de regressão múltipla com dados da Tabela 4 em Excel .....	74
Quadro 8 – Resultados da análise de regressão PLS com dados codificados da Tabela 5 em Minitab .....	75
Quadro 9 – Resultados da análise através da função <i>Best Subset</i> em Minitab .....	76
Quadro 10 – Resultados da análise de regressão com dados reais da Tabela 6 em Minitab .....	77
Quadro 11 – Dados coletados pelo time multifuncional a cada período (mensal) .....	93
Quadro 12 – Parâmetros do módulo MRP e classificação obtidos pelo time multifuncional .....	95
Quadro 13 – Conjunto de variáveis utilizada para aplicação da análise discriminante .....	96
Quadro 14 – Resultados da análise discriminante com as variáveis do Quadro 13 .....	96
Quadro 15 – Projeção da deterioração do estoque de matérias primas através de regressão múltipla em Minitab .....	100
Quadro 16 – Redução das variáveis através da função <i>Best Subset</i> em Minitab .....	101
Quadro 17 – Variáveis utilizadas para regressão PLS .....	102



## LISTA DE TABELAS

Tabela 1 – Classes de idade do inventário e provisão para perdas .....	63
Tabela 2 – Projeção do envelhecimento do estoque de produtos acabados através de regressão linear em Excel .....	72
Tabela 3 – Projeção do envelhecimento do estoque de produtos acabados através de regressão múltipla em Excel .....	73
Tabela 4 – Dados utilizados na regressão múltipla da análise 16 da Tabela 3 .....	74
Tabela 5 – Dados codificados utilizados na regressão PLS em Minitab .....	75
Tabela 6 – Dados reais utilizados na regressão em Minitab após a aplicação da ferramenta <i>Best Subset</i> .....	77
Tabela 7 – Projeção do envelhecimento do inventário de produtos acabados através de regressão PLS em Minitab .....	79
Tabela 8 – Coeficientes de regressão gerados mensalmente de junho a novembro de 2015 com base nos replanejamentos mensais .....	83
Tabela 9 – Envelhecimento do inventário com base nos replanejamentos mensais realizados de junho a novembro de 2015 .....	83
Tabela 10 – Valor total do inventário acima de 180 dias com base nos replanejamentos mensais realizados de junho a novembro de 2015 .....	84
Tabela 11 – Variação entre o previsto e o realizado mensalmente para o valor total do inventário acima de 180 dias .....	85
Tabela 12 – Função discriminante linear com as variáveis do Quadro 13 .....	97
Tabela 13 – Classificação das matérias primas cadastradas após maio de 2017 .....	97
Tabela 14 – Novos itens cadastrados no sistema ERP após maio de 2017 que apresentaram descarte por vencimento da data de validade .....	98
Tabela 15 – Variáveis utilizadas para regressão linear múltipla da deterioração do inventário de matérias primas em Minitab .....	99
Tabela 16 – Projeção da deterioração do inventário de matérias primas através de regressão PLS em Minitab .....	104

Tabela 17 – Coeficientes de regressão gerados mensalmente de abril a outubro de 2017 com base nos replanejamentos mensais .....	108
Tabela 18 – Descarte de matérias primas deterioradas e as variáveis selecionadas de maio a outubro de 2017.....	108
Tabela 19 – Valores previstos e realizados mensalmente para o descarte de matérias primas .....	109
Tabela 20 – Inventário menor do que 180 dias (C1) por período – previsto vs. realizado ...	130
Tabela 21 – Venda (C2) por período – previsto vs. realizado .....	130
Tabela 22 – Devoluções (C4) por período – previsto vs. realizado .....	130
Tabela 23 – Performance do FIFO (C5) por período – previsto vs. realizado .....	130
Tabela 24 – Venda (X1) por período – previsto vs. realizado .....	131
Tabela 25 – CPV (X2) por período – previsto vs. realizado .....	131
Tabela 26 – Compra de matérias primas (X3) por período – previsto vs. realizado .....	131
Tabela 27 – Inventário de matérias primas (X4) por período – previsto vs. realizado .....	131
Tabela 28 – Inventário de produtos acabados (X5) por período – previsto vs. realizado .....	132
Tabela 29 – Consumo de matérias primas (X6) por período – previsto vs. realizado .....	132
Tabela 30 – Produtos prontos (X7) por período – previsto vs. realizado .....	132
Tabela 31 – Volume de produção (X8) por período – previsto vs. realizado .....	132

## LISTA DE ABREVIATURAS E SIGLAS

ANCOVA	Análise de Covariância
ANOVA	Análise de Variância
ANVISA	Agência Nacional de Vigilância Sanitária
BS	<i>Backward Selection</i>
BSS	<i>Best Subset Selection</i>
CBSE	<i>Covariance-Based SEM</i>
Cp	Critério Cp de Mallow
CPV	Custo do Produto Vendido
DRE	Demonstrativo de Resultado do Exercício
EOQ	<i>Economic Order Quantity</i>
ERP	<i>Enterprise Resource Planning</i>
FIFO	<i>First-In First-Out</i>
FLDA	<i>Fischer Linear Discriminant Analysis</i>
FS	<i>Forward Selection</i>
IASB	<i>International Accounting Standard Board</i>
IFRS	<i>International Financial Reporting Standard</i>
LDA	<i>Linear Discriminant Analysis</i>
MANCOVA	Análise Multivariada de Covariância
MANOVA	Análise Multivariada de Variância
ME	Material de Embalagem
MLR	<i>Multiple Linear Regression</i>
MP	Matéria prima
MRP	<i>Material Requirement Planning</i>
NIPALS	<i>Non-linear Iterative Partial Least Squares</i>

OPLS	PLS Ortogonal
OPLS-DA	Análise Discriminante PLS Ortogonal
P&D	Pesquisa e Desenvolvimento
PCA	<i>Principal Component Analysis</i>
PCP	Planejamento e Controle da Produção
PLS	<i>Partial Least Squares</i>
PLS2	PLS Multiresposta (contínua)
PLS-DA	Análise Discriminante PLS
PLSR	<i>Partial Least Squares Regression</i>
QDA	<i>Quadratic Discriminant Analysis</i>
S&OP	<i>Sales and Operations Planning</i>
SEM	<i>Structural Equation Modeling</i>
SLR	<i>Simple Linear Regression</i>
SMR	<i>Stepwise Multiple Regression</i>
SR	<i>Simple Regression</i>
VMI	<i>Vendor Managed Inventory</i>
WMS	<i>Warehouse Management System</i>

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	1
1.1. CONSIDERAÇÕES INICIAIS .....	1
1.2. OBJETIVOS E TEMA .....	2
1.3. JUSTIFICATIVA DO TEMA E OBJETIVOS .....	3
1.4. MÉTODO .....	4
1.5. ESTRUTURA DO TRABALHO .....	5
1.6. DELIMITAÇÕES DO TRABALHO .....	6
<b>2. FUNDAMENTAÇÃO TEÓRICA</b> .....	7
2.1. DIRETRIZES PARA REDUÇÃO DO INVENTÁRIO COM RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO .....	7
<b>2.1.1. Causas da obsolescência e deterioração de estoques e seus prejuízos</b> .....	8
<b>2.1.2. Modelagem matemática e técnicas estruturadas voltadas à redução do risco             de obsolescência e deterioração de estoques</b> .....	12
2.2. FERRAMENTAS MULTIVARIADAS .....	19
<b>2.2.1. Condições para aplicação de técnicas multivariadas</b> .....	23
<b>2.2.2. Regressão linear múltipla</b> .....	24
<b>2.2.3. Regressão PLS</b> .....	32
<b>2.2.4. Análise discriminante</b> .....	36
2.3. SELEÇÃO DE VARIÁVEIS .....	40
<b>2.3.1. Seleção de variáveis em contexto de PLS</b> .....	42
<b>3. MÉTODO</b> .....	47
3.1. INVESTIGAR OS FATORES QUE CONTRIBUEM PARA O AUMENTO DA IDADE DO INVENTÁRIO .....	48
<b>3.1.1. Identificar o problema</b> .....	48
<b>3.1.2. Organizar time multifuncional</b> .....	48
<b>3.1.3. Identificar regras e procedimentos aplicáveis a estoques obsoletos ou             deteriorados</b> .....	49
<b>3.1.4. Identificar fatores que podem gerar estoque obsoleto ou deteriorado</b> .....	49
3.2. CLASSIFICAR O ESTOQUE EM FAIXAS DE IDADE PARA MENSURAR O RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO DO INVENTÁRIO ...	50

<b>3.2.1. Coletar dados</b> .....	50
<b>3.2.2. Classificar o estoque por tipo de item</b> .....	50
<b>3.2.3. Classificar o estoque em faixas de idade</b> .....	51
<b>3.3. DEFINIR O CONJUNTO DE VARIÁVEIS MAIS APROPRIADO PARA PROJEÇÃO DO INVENTÁRIO AO LONGO DO TEMPO</b> .....	53
<b>3.3.1. Estudar o processo e variáveis</b> .....	54
<b>3.3.2. Definir as variáveis</b> .....	54
<b>3.3.3. Selecionar as variáveis mais relevantes para o propósito de predição</b> .	54
<b>3.3.4. Projetar o estoque ao longo do tempo</b> .....	55
<b>3.4. DEFINIR O CONJUNTO DE DIRETRIZES MAIS APROPRIADAS PARA REDUÇÃO DO INVENTÁRIO COM RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO</b> .....	56
<b>3.4.1. Revisar o objetivo e definir a linha de base</b> .....	56
<b>3.4.2. Definir o plano de ação consolidado e o calendário das reuniões periódicas</b> .....	57
<b>3.5. GESTÃO DA REDUÇÃO DO RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO DO INVENTÁRIO</b> .....	58
<b>3.5.1. Coletar dados atualizados</b> .....	58
<b>3.5.2. Projetar o estoque</b> .....	58
<b>3.5.3. Atualizar resultados e avaliar eficácia das ações</b> .....	59
<b>3.5.4. Padronizar e revisar ações corretivas</b> .....	59
<b>3.5.5. Rever objetivos e estabelecer novas metas</b> .....	60
<b>4. ESTUDO DE CASO 1</b> .....	61
<b>4.1. CARACTERIZAÇÃO DA EMPRESA</b> .....	61
<b>4.2. APLICAÇÃO DO MÉTODO</b> .....	63
<b>4.2.1. Investigar os fatores que contribuem para o aumento da idade do inventário</b> .....	63
<b>4.2.1.1. Identificar o problema</b> .....	63
<b>4.2.1.2. Organizar time multifuncional</b> .....	64
<b>4.2.1.3. Identificar regras e procedimentos aplicáveis a estoques obsoletos ou deteriorados</b> .....	65
<b>4.2.1.4. Identificar fatores que podem gerar estoque obsoleto ou deteriorado</b> .....	66

<b>4.2.2. Classificar o estoque em faixas de idade para mensurar o risco de obsolescência ou deterioração do inventário</b> .....	66
4.2.2.1. Coletar dados .....	66
4.2.2.2. Classificar o estoque por tipo de item .....	68
4.2.2.3. Classificar o estoque em faixas de idade .....	70
<b>4.2.3. Definir o conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo</b> .....	71
4.2.3.1. Estudar o processo e variáveis .....	71
4.2.3.2. Definir as variáveis .....	71
4.2.3.3. Selecionar as variáveis mais relevantes para o propósito de predição .....	74
4.2.3.4. Projetar o estoque ao longo do tempo .....	77
<b>4.2.4. Definir o conjunto de diretrizes mais apropriadas para redução do inventário com risco de obsolescência ou deterioração</b> .....	79
4.2.4.1. Revisar o objetivo e definir a linha de base .....	79
4.2.4.2. Definir o plano de ação consolidado e o calendário das reuniões periódicas .....	80
<b>4.2.5. Gestão da redução do risco de obsolescência ou deterioração do inventário</b> .....	81
4.2.5.1. Coletar dados atualizados .....	81
4.2.5.2. Projetar o estoque .....	81
4.2.5.3. Atualizar resultados e avaliar eficácia das ações .....	81
4.2.5.4. Padronizar e revisar ações corretivas .....	82
4.2.5.5. Rever objetivos e estabelecer novas metas .....	82
<b>5. ESTUDO DE CASO 2</b> .....	87
5.1. CARACTERIZAÇÃO DA EMPRESA .....	87
5.2. APLICAÇÃO DO MÉTODO .....	88
<b>5.2.1. Investigar os fatores que contribuem para o aumento da idade do inventário</b> .....	88
5.2.1.1. Identificar o problema .....	88
5.2.1.2. Organizar time multifuncional .....	90
5.2.1.3. Identificar regras e procedimentos aplicáveis a estoques obsoletos ou deteriorados .....	90

5.2.1.4. Identificar fatores que podem gerar estoque obsoleto ou deteriorado .....	91
<b>5.2.2. Classificar o estoque em faixas de idade para mensurar o risco de obsolescência ou deterioração do inventário .....</b>	<b>92</b>
5.2.2.1. Coletar dados .....	92
5.2.2.2. Classificar o estoque por tipo de item .....	93
5.2.2.3. Classificar o estoque em faixas de idade .....	98
<b>5.2.3. Definir o conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo .....</b>	<b>98</b>
5.2.3.1. Estudar o processo e variáveis .....	98
5.2.3.2. Definir as variáveis .....	99
5.2.3.3. Selecionar as variáveis mais relevantes para o propósito de predição .....	100
5.2.3.4. Projetar o estoque ao longo do tempo .....	102
<b>5.2.4. Definir o conjunto de diretrizes mais apropriadas para redução do inventário com risco de obsolescência ou deterioração .....</b>	<b>104</b>
5.2.4.1. Revisar o objetivo e definir a linha de base .....	104
5.2.4.2. Definir o plano de ação consolidado e o calendário das reuniões periódicas .....	105
<b>5.2.5. Gestão da redução do risco de obsolescência ou deterioração do inventário .....</b>	<b>106</b>
5.2.5.1. Coletar dados atualizados .....	106
5.2.5.2. Projetar o estoque .....	107
5.2.5.3. Atualizar resultados e avaliar eficácia das ações .....	107
5.2.5.4. Padronizar e revisar ações corretivas .....	107
5.2.5.5. Rever objetivos e estabelecer novas metas .....	107
<b>6. DISCUSSÃO DOS RESULTADOS .....</b>	<b>112</b>
<b>7. CONCLUSÃO .....</b>	<b>116</b>
<b>REFERÊNCIAS .....</b>	<b>118</b>
<b>APÊNDICE A .....</b>	<b>130</b>
<b>APÊNDICE B .....</b>	<b>131</b>



## 1. INTRODUÇÃO

### 1.1. CONSIDERAÇÕES INICIAIS

Ao observar-se o desempenho das empresas ao longo do tempo, seja em ambientes macroeconômicos favoráveis ou desfavoráveis, percebe-se que algumas companhias se destacam de suas concorrentes ou mesmo de empresas de setores distintos. Isto se deve ao fato das empresas não serem influenciadas uniformemente pelo cenário macroeconômico ou pelo macro ambiente do setor em que estão inseridas, devido às suas características econômico-financeiras particulares e vantagens competitivas que conquistaram através de suas estratégias de gestão (Campos, 2009).

Tal situação pode ser observada na indústria de bens de consumo no Brasil, a qual, independentemente do setor, apoia-se em redes varejistas para escoar sua produção. Dentro da relação de dependência mútua da indústria e do varejo, é notório observar que as redes varejistas, principalmente as de maior porte, aumentaram muito seu poder de negociação frente às indústrias nas últimas décadas. Isso acarreta uma concentração do mercado entre poucos fabricantes, tornando-os intensamente competitivos e concentrados em oferecer produtos de alta qualidade, enquanto as vendas passam a ser direcionadas pela disponibilidade de produtos em estoque no varejo, e não mais pelo poder e lealdade a uma marca específica (Campos, 2009, Lambert et al., 1998).

A viabilidade de qualquer negócio, do ponto de vista da liquidez e rentabilidade, depende da capacidade de gerenciamento dos recebíveis, do inventário e das contas a pagar. A má gestão do capital de giro reduz a liquidez da empresa e limita a obtenção de vantagens competitivas, afetando a sua rentabilidade. Em muitos casos, os investimentos desnecessários estão relacionados ao estoque, que é o maior componente do capital de giro e um dos elementos principais do ativo circulante. Uma empresa que negligencia a gestão dos inventários potencializa o risco de problemas relacionados à rentabilidade a longo prazo e compromete sua capacidade de sobrevivência (Panigrahi, 2013).

Fisher (2003) afirma que a incerteza da reação do mercado às inovações tecnológicas aumenta o risco de falta ou de excesso de estoques, e que o ciclo de vida curto aumenta o risco de obsolescência do inventário. Wild (2007) cita que variações na demanda dos clientes, alterações repentinas nas estratégias de vendas, atualizações de linhas de produtos e lançamento de novos produtos também contribuem para geração de inventários obsoletos. Neste contexto, a correta mensuração do custo do inventário, considerando os riscos de manutenção de inventário em excesso e também da indisponibilidade de itens em estoque e seu impacto nas vendas, torna a

definição de medidas de desempenho logístico (incluindo a mensuração dos custos relacionados a obsolescência do estoque) um importante instrumento de gestão para obtenção de vantagem competitiva (Beamon, 1999).

A manutenção da vantagem competitiva depende da habilidade da empresa em avaliar uma grande quantidade de informações provenientes do ambiente onde está inserida e de seus processos internos (Porter, 1992). No caso da indústria de bens de consumo, a alta competitividade do mercado e a concentração do poder de venda nas redes varejistas tornam a projeção dos saldos de inventário e do risco de obsolescência ao final de cada período um grande desafio para as empresas, dado a quantidade de variáveis envolvidas. De tal forma, percebe-se que a utilização de ferramental quantitativo, dentre o qual destaca-se a modelagem de regressão, pode oferecer subsídios para tomada de decisão com maior precisão.

Segundo Montgomery (2008), métodos de regressão são usados com frequência para analisar dados de experimentos não planejados, como os decorrentes da observação de fenômenos não controlados ou de registros históricos. Segundo afirmam Kasznar e Gonçalves (2011), o modelo de regressão múltipla permite que se estime o valor de uma variável dependente com base em um conjunto de outras variáveis, tidas como independentes. Quanto mais significativo for o peso de uma variável isolada (ou de um conjunto de variáveis independentes), tanto mais se poderá afirmar que determinados fatores afetam de forma mais intensa o comportamento da variável de resposta. A utilização de número demasiado de variáveis independentes na construção do modelo, no entanto, pode comprometer a capacidade preditiva do modelo de regressão gerado.

## 1.2. OBJETIVOS E TEMA

O tema deste trabalho consiste na proposição de uma abordagem para classificação, projeção e controle da obsolescência de inventários apoiada em ferramentas multivariadas.

Seu objetivo geral é propor uma abordagem para selecionar variáveis independentes em modelos de regressão preditivos com vistas à classificação de inventários de itens e a projeção deste inventário ao longo do tempo a partir de um conjunto recomendado de variáveis. Entre os objetivos específicos deste trabalho estão: (i) investigar os fatores que contribuem para o aumento da idade do inventário; (ii) classificar o estoque e os produtos em faixas de idade para mensurar o risco de obsolescência do inventário; (iii) definir o conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo; e (iv) definir o conjunto de diretrizes mais apropriadas para redução do inventário com risco de obsolescência ou deterioração.

### 1.3. JUSTIFICATIVA DO TEMA E OBJETIVOS

O curto ciclo de vida dos produtos, o poder elevado de negociação dos varejistas e as provisões contábeis para perda de valor do estoque tornam a projeção dos saldos de inventário ao final de cada período um importante aliado para manutenção da saúde financeira das empresas. A incerteza da reação do mercado às inovações tecnológicas aumenta o risco de falta ou de excesso de estoques, e o ciclo de vida curto aumenta o risco de obsolescência do inventário. A minimização de estoques obsoletos deve ser um dos principais objetivos e objeto de medição de performance nas empresas, incluindo o custo do inventário, o riscos de manutenção de inventário em excesso, o risco de indisponibilidade de itens em estoque e seu impacto nas vendas e os custos relacionados à obsolescência do estoque (Beamon, 1998; Beamon, 1999; Fisher, 2003).

Além disso, o lançamento de provisões contábeis para obsolescência do estoque em função da idade do inventário, utilizada nos balanços que seguem o padrão de contabilidade internacional (IFRS – *International Financial Reporting Standard*), publicado pelo Colegiado de Padrões Contábeis Internacionais (IASB - *International Accounting Standard Board*), padrão para o qual as normas contábeis brasileiras têm convergido, aumenta a importância do monitoramento e controle do risco de obsolescência dos produtos (Silva et al., 2011; Cella et al., 2011; Thomaz et al., 2013; Souza e Coutinho Filho, 2007). No entanto, poucas pesquisas foram realizadas sobre o gerenciamento de operações considerando processos de envelhecimento do inventário (Wu, 2013), o que justifica o presente estudo sob perspectiva prática.

No aspecto teórico, a revisão da literatura de gestão de estoques mostra que a maior parte dos modelos matemáticos de gestão de inventário tem como foco as questões relativas ao excesso e falta de inventário e o processo de suprimentos. Estes modelos não abordam, geralmente, o risco de obsolescência, visto que itens obsoletos são retirados do estoque e não são comprados novamente (Bonney e Jaber, 2011; Bakker et al., 2012). A maioria dos modelos matemáticos de gestão de inventário disponíveis na literatura recente aplica-se a questões de planejamento de estoques em ambientes de produção e distribuição, gestão de componentes de bens de capital com longo ciclo de vida ou de peças de reposição, com foco em quanto manter de estoque de cada produto ou componente (Wanke, 2005). Embora a revisão de literatura tenha identificado alguns autores que desenvolveram modelos matemáticos de revisão de inventário que incluem o risco de obsolescência (Pinçe e Dekker, 2011; Nenes et al., 2010; Wong et al., 2006), estes modelos não projetam o risco de obsolescência futuro nem visam à criação de estratégias para

redução do risco de obsolescência de inventário de produtos acabados. Desta forma, esse estudo justifica-se também no âmbito teórico.

#### 1.4. MÉTODO

Pesquisar significa procurar respostas para problemas propostos através de um conjunto de ações com vistas a encontrar a solução para um problema, tendo por base procedimentos racionais e sistemáticos. De tal forma, realiza-se uma pesquisa quando se tem um problema e não se tem informações para solucioná-lo, ou quando a informação disponível se encontra de forma desordenada, não podendo ser relacionada ao problema de forma adequada (Silva e Menezes, 2005; Gil, 2010).

Este trabalho é de natureza aplicada, visto que propõe o desenvolvimento de um método que pode ser utilizado para análise e redução do risco de obsolescência do inventário em empresas produtoras de bens de consumo. O trabalho inicialmente utiliza abordagem qualitativa (descritiva, não requerendo o uso de técnicas estatísticas) para investigação dos fatores que contribuem para o aumento da idade do inventário. Também utiliza abordagem quantitativa para definição do conjunto de variáveis mais apropriadas para projeção do inventário ao longo do tempo através de técnicas de regressão (Silva e Menezes, 2005).

Quanto aos objetivos, o trabalho é classificado como pesquisa explicativa, a qual tem como principal objetivo identificar os fatores que determinam ou contribuem para a ocorrência dos fenômenos. De tal forma, permite propor e testar um modelo para projetar valores futuros de determinado processo ou indicador de uma empresa através da seleção do conjunto de variáveis adequado de seus dados históricos e projeções financeiras, sobre os quais serão aplicados métodos de predição estatística (Gil, 2010). Finalmente, quanto aos procedimentos, o trabalho é classificado como pesquisa ação (concebida e realizada em estreita associação com uma ação ou com a resolução de um problema coletivo) (Gil, 2010).

O desenvolvimento desta pesquisa será realizado a partir de quatro etapas: (i) revisão da literatura; (ii) estudo do cenário da empresa; (iii) definição do conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo; (iv) implantação do método e discussão dos resultados obtidos.

A primeira etapa compreende a revisão da literatura de gestão de estoques, ferramentas multivariadas e seleção de variáveis, buscando conhecimentos sobre gestão de estoques e obsolescência de inventário, regressão linear múltipla, regressão por mínimos quadrados parciais (PLSR - *Partial Least Squares Regression*), análise discriminante e métodos de seleção

de variáveis. A revisão da literatura foi realizada através da busca em bases de dados acadêmica, em periódicos e livros.

A segunda etapa envolve o estudo do cenário da empresa, seu inventário e as características do mercado em que atua, de forma a entender o contexto do negócio e as variáveis que podem influenciar no risco de obsolescência do estoque. Esta etapa demanda pesquisa com especialistas de diversas áreas da empresa para avaliar as variáveis do negócio que possam ter impacto na obsolescência do estoque e que possam ser consideradas potenciais variáveis independentes do modelo.

A terceira etapa engloba a classificação do inventário e dos produtos em faixas de idade, além da definição do conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo. Esta etapa será realizada com base na pesquisa documental com suporte de especialistas de diversas áreas da empresa para definir a classificação mais apropriada do estoque e dos produtos e selecionar as variáveis, suas características mensuráveis e o relacionamento destas com o risco de obsolescência do inventário.

A quarta etapa envolve a implantação da classificação do estoque e dos produtos, a análise das projeções financeiras da empresa, a projeção do inventário ao longo do tempo e a discussão dos resultados obtidos. Esta etapa também será realizada em conjunto com os especialistas da empresa, e envolve a coleta de dados de estoque, planejamento de demanda e produção e previsões financeiras da empresa. A discussão dos resultados obtidos envolve a coleta e análise de dados e do desempenho da empresa antes e depois da implantação do método, com base em dados numéricos.

O método será, então, validado pelos especialistas da empresa em conjunto com o pesquisador, para garantir que os resultados são os que melhor representam os dados, sendo, portanto, extensivos a outros cenários de análise.

## 1.5. ESTRUTURA DO TRABALHO

Este trabalho está estruturado como segue. Além desta introdução, a segunda seção trata da revisão da literatura de gestão de estoques e diretrizes para redução do inventário com risco de obsolescência, métodos multivariados e seleção de variáveis utilizando múltiplos critérios, conhecimentos essenciais para proposição do conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo. A terceira seção traz o método proposto, ao passo que a quarta e a quinta seção apresentam os estudos de caso com os resultados obtidos. A sexta seção traz as conclusões do estudo.

## 1.6. DELIMITAÇÕES DO TRABALHO

O presente trabalho apresenta uma metodologia para projeção do saldo de inventário de produtos acabados ao final de cada período em indústrias fabricantes de bens consumo que fornecem a grandes redes varejistas. A utilização da metodologia proposta em outras indústrias ou para tratamento do inventário de componentes ou de peças de reposição certamente requer adaptações. Além disso, a metodologia proposta irá projetar o saldo de inventário ao final de cada período (no fechamento contábil de cada mês), logo, a utilização desta metodologia para projetar o saldo de inventário em qualquer outro momento ao longo de um determinado período certamente irá exigir adaptações. Por fim, não são estimados custos de obsolescência dos produtos analisados.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1. DIRETRIZES PARA REDUÇÃO DO INVENTÁRIO COM RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO

A fim de evitar o insucesso empresarial e os danos às empresas, vários métodos de previsão de falhas de negócios têm sido apresentados ao longo dos últimos anos, com base em modelos estatísticos clássicos, modelos de inteligência artificial ou modelos teóricos. Estes métodos têm como objetivo oferecer ferramentas à gestão para desenvolver sistemas de alerta precoces em caso de falhas iminentes dos negócios ou permitir uma melhor tomada de decisão na avaliação dos resultados, de forma a habilitar possíveis investidores a selecionar empresas saudáveis para investir, ou mesmo para futuros trabalhadores poderem fazer uso de métodos de previsão de falha robustos na triagem de empresas para se trabalhar (Aziz e Dar, 2006).

Huang et al. (2005) citam que estudos anteriores relacionados com a previsão de falhas utilizavam principalmente métodos estatísticos (entre eles, a análise de regressão) mas que recentemente tornou-se popular a aplicação de técnicas de inteligência artificial e aprendizagem automática. Enormes quantidades de dados são rotineiramente coletadas nas empresas, e extrair informações úteis a partir destes dados é essencial para a tomada de decisões para a melhoria de processos e otimização dos negócios, tornando-se uma questão estratégica para o sucesso industrial no atual mercado global competitivo (Ferrer et al., 2008).

A suposição de que os bens no inventário sempre preservam suas características físicas não é verdade em geral porque existem alguns itens que são sujeitos a riscos de quebras, evaporação, obsolescência, etc. (Valliathal e Uthayakumar, 2010). A manutenção de inventários geralmente demanda investimentos e acarreta em perda financeira devido ao custo de manutenção do estoque e ao custo de obsolescência. Enquanto os investimentos (ou custos) da manutenção de estoques ocorrem durante um determinado intervalo de tempo, a perda financeira (ou custo) decorrente da obsolescência ocorre em um ponto específico no tempo. (Song e Lau, 2004).

Katok et al. (2001), em sua pesquisa sobre um sistema para gerenciar estoques em uma empresa fornecedora de produtos de informação para a indústria aeronáutica, apresentam um breve relato sobre a origem da literatura envolvendo estoques obsoletos. Segundo os autores, a primeira definição do problema de estoques obsoletos incluindo uma comparação numérica de sistemas com e sem obsolescência foi estabelecida na pesquisa de E. W. Barankin e J. Denny, em 1965, segundo os quais obsolescência significa que o item em questão não deve mais ser usado e o estoque disponível deve ser descartado. Posteriormente, em 1969, William P. Pierskalla examinou mais profundamente as propriedades teóricas do modelo de obsolescência

com demanda determinista quando os custos de manutenção e de escassez do estoque são funções convexas continuamente diferenciáveis. O estudo sobre a obsolescência de inventários prosseguiu com Steven Nahmias em 1977, em sua pesquisa sobre inventários perecíveis com demanda e vida útil aleatórias e estocásticas, com Donald B. Rosenfeld, que também considerou o problema com a demanda estocástica e a probabilidade de obsolescência quando o estoque obsoleto tem valor residual, em sua pesquisa de 1989, e por Eugene F. Finkin, que também em 1989 sugeriu maneiras de gerenciar estoques obsoletos na prática.

A literatura recente sobre gestão da cadeia de suprimento e gestão de inventários traz diversas abordagens sobre o risco de obsolescência de inventário. Singh et al. (2008) afirmam que um grande número de pequenas e médias empresas operam com sistemas de previsão e de planejamento deficitários, com os sistemas de controle de inventário não confiáveis, sem rastreamento de estoque e controle de custos ineficientes, podendo levar a excesso de estoque obsoleto e à corrosão dos níveis de serviço ao cliente. Para Slone et al. (2007), muitas empresas medem apenas o que podem avaliar facilmente, e poucas conhecem o custo total do inventário que carregam ou se dão ao trabalho de medir o custo real do estoque obsoleto. De acordo com Jennings (2015), nos últimos anos muitas abordagens para a previsão de obsolescência têm sido desenvolvidas, porém, com base em entradas manuais e melhores estimativas de especialistas da área. Van Jaarsveld e Dekker (2010), por sua vez, apontam em seu estudo sobre a estimativa do risco de obsolescência em peças de reposição que há poucas abordagens diferentes disponíveis na literatura para a incorporação do risco de obsolescência em modelos de gestão de estoque.

No modelo clássico de lote econômico de compra a taxa de demanda é considerada constante, porém, na vida real, a taxa de demanda para bens físicos pode depender do tempo, do preço e do estoque. Observa-se que nos supermercados a taxa de demanda geralmente é influenciada pela quantidade de produtos em exposição. No varejo em geral, a presença de uma quantidade maior de produtos expostos na prateleira pode atrair mais clientes do que uma quantidade menor de mercadorias. Assim, construir um bom inventário geralmente tem um impacto positivo nas vendas e lucro, porém, os varejistas que lidam com produtos perecíveis devem considerar os fatores tempo de vida útil e a dependência da quantidade de estoque exposta no volume de vendas para determinar a política de compras e de estoque ótimas (Nagare e Dutta, 2012; Tripathia e Mishra, 2014; Tayal et al., 2014).

### **2.1.1. Causas da obsolescência e deterioração de estoques e seus prejuízos**



Panigrahi (2013) define inventário como o estoque dos produtos que uma empresa oferece para venda e os vários componentes que compõem esses produtos (matérias-primas, bens em processo, produtos acabados e peças sobressalentes). Utilizando a terminologia contábilística, inventário é o agregado destes bens tangíveis que: (i) são mantidos para venda no curso normal dos negócios; (ii) estão em processo de produção para tal venda, e; (iii) estarão disponíveis para venda após conclusão do processo de produção.

Para Chopra e Sodhi (2004), o risco de inventário depende de três fatores: o valor do produto, a sua taxa de obsolescência e incerteza da demanda e da oferta. A importância da gestão de estoques inclui a determinação dos requisitos atuais e futuros de todos os tipos de inventário para evitar o excesso de estoques, o estrangulamento da produção (gargalos produtivos), a segurança dos suprimentos, a prevenção da deterioração, o roubo e a obsolescência (Kamau e Kagiri, 2015).

Quanto a incerteza da oferta, Zsidisin e Ellram (2003) afirmam que, embora os estoques de segurança reduzam significativamente o risco de fornecimento (permitindo que as empresas respondam às variações no fluxo de suprimento, problemas de suprimento ou dificuldades internas de produção), estes estoques contribuem para o aumento dos custos de armazenamento (devido a necessidade adicional de espaço, manuseio e seguro) e para o aumento do risco de obsolescência. Para Michalski (2008), objetivo básico da administração financeira de estoques é manter o estoque no menor nível aceitável em função dos custos de manutenção, do capital usado para financiar o estoque, dos custos de armazenagem, seguro, transporte e obsolescência. Porém, o autor alerta que baixo nível de estoque pode afetar o fornecimento de produtos aos clientes, incorrendo em custos de desabastecimento e perda de receitas.

Butt et al. (2015) definem obsolescência como a diminuição do valor e/ou utilidade de um sistema como um todo, ou de seu componente, devido a uma diminuição da conveniência e/ou função, a partir de uma multiplicidade de causas tais como novas invenções, mudanças no design, desenvolvimento tecnológico, melhoria do processo de produção, mudança no uso ou nas demandas do usuário final, mudanças climáticas ou alterações políticas ou de legislação. O autor também define obsolescência financeira (ou obsolescência social ou econômica) como sendo a perda de valor, e obsolescência funcional (ou técnica) como a perda de utilidade, eficácia, eficiência ou produtividade. Para Song e Lau (2004) a perda de valor do inventário de um determinado item devido a obsolescência pode ser parcial ou total.

Chae (2009) aponta que estoques obsoletos são uma das principais fontes de aumento do custo total do inventário, e que o monitoramento regular do nível de estoques reduz o custo total do

inventário, ao passo que Thummalapalli (2010) afirma que a obsolescência de estoques se tornou um fenômeno de destaque na maioria das organizações, as quais estão se esforçando para evitar estoques obsoletos e estoques excessivos. Segundo Tang e Musa (2011), a rápida evolução tecnológica, alterações na demanda dos clientes e excesso de inventário podem expor as empresas ao risco de obsolescência do inventário. Krajčovič e Plinta (2012) afirmam que inventários obsoletos são a fonte de capital morto que causa grandes perdas para uma empresa, sendo que o valor destas perdas depende do tempo e do valor agregado no processo de fabricação, e ponderam que as ferramentas eficientes de gestão de inventário devem não apenas identificar inventário obsoleto existente, mas também ajudar na prevenção de novos estoques obsoletos no futuro.

Pingle (2015) afirma que a maioria das ferramentas ou abordagens utilizadas para gerenciar ou mitigar a obsolescência visa minimizar o custo total do gerenciamento da obsolescência. Existem, porém, outros fatores além do custo que devem ser considerados ao escolher uma estratégia de resolução da obsolescência, tais como a demanda do mercado do produto durante a implantação da solução, o desempenho, a sustentabilidade e o tempo disponível para a implementação da solução.

Kessler e Brendel (2016) classificam obsolescência em quatro diferentes grupos: (i) obsolescência qualitativa (ou obsolescência física) refere-se a produtos com uma vida útil funcional limitada, possibilidade limitada de reparo e desgaste rápido; (ii) obsolescência psicológica, quando produtos parecem “desgastados” em comparação ao design de novos produtos ou novas gerações de um mesmo produto; (iii) obsolescência tecnológica, que inclui o aperfeiçoamento funcional por adição ou atualização das características do produto, e; (iv) obsolescência regulatória, a qual ocorre quando o produto ou seus componentes têm de ser substituídos após um determinado tempo ou uso devido a requisitos legais. Já Kumar e Saranga (2010), citam como as principais causas da obsolescência do inventário: (i) a diminuição das fontes de produção desencadeada pelo rápido progresso tecnológico; (ii) o ciclo de vida dos bens de capital maior do que o ciclo de vida de seus componentes integrados, e; (iii) a obsolescência planejada por muitos fabricantes de bens duráveis. Pourakbar et al. (2012) reforçam que os componentes que compõem um produto acabado têm ciclos de vida próprios e podem tornar-se obsoletos antes do fim do ciclo de vida do produto. A falta de sincronia entre os ciclos de vida do produto e de seus componentes é denominada incompatibilidade do ciclo de vida (*life cycle mismatch*) (Solomon et al., 2000). Pingle (2015) alerta que as tendências do mercado, as demandas dos clientes e a concorrência levam os fabricantes a atualizar os produtos

constantemente para manter a sua participação no mercado, o que faz com que os produtos existentes se tornem obsoletos. Este tipo de obsolescência forçada (já que os fabricantes precisam atualizar os produtos devido à pressão do mercado) é chamada pelo autor de FIDO (*Functionality Improvement Dominated Obsolescence*). O autor ainda cita que aproximadamente 3% do total de componentes de equipamentos eletrônicos no mundo todo tornam-se obsoletos a cada mês, tornando o efeito da obsolescência um dos maiores custos da indústria de itens de longo ciclo de vida.

Embora existam diversos critérios para mensurar a importância de um item de estoque que vão além do valor anual de compra do item - entre eles, a criticidade do item, a escassez, a capacidade de estocagem, o tempo de espera (*lead time*), a durabilidade e o risco de obsolescência, muitos métodos de tomada de decisão tradicionais não incluem todos estes critérios (Ramanathan, 2006; Ng, 2007; Cakir e Canbolat, 2008; Boylan et al., 2008). Van Donk e Van Der Vaart (2005) alertam que a ausência de informações resulta em custos desnecessários relacionados ao nível de inventário e risco de obsolescência, principalmente em ambientes de baixos volumes e elevado mix de produtos.

Stank et al. (2011) mostram que algumas empresas já trabalham com a consciência de que a excelência da cadeia de abastecimento também começa com a concepção do produto, visto que, à medida em que novos produtos são projetados e introduzidos, quatro problemas crônicos costumam surgir e prejudicar a cadeia de suprimentos: excesso de inventário obsoleto, excessiva complexidade da linha de produtos, previsões ruins e gestão da demanda ineficaz.

Bakker et al. (2012), em sua revisão da literatura sobre trabalhos acadêmicos relacionados ao risco de deterioração do inventário, diferenciam a deterioração do inventário (definido como o dano, deterioração, vaporização, secura, etc. dos produtos) da obsolescência (perda de valor com o tempo devido a evolução tecnológica ou introdução de novos produtos). O inventário perecível constitui uma grande parte da economia mundial e inclui praticamente todos os produtos alimentares, produtos farmacêuticos, produtos de moda, itens eletrônicos, periódicos, bens digitais entre outros, à medida em que perdem valor com o tempo devido a deterioração e/ou obsolescência. Por este motivo, a exemplo da obsolescência, a deterioração de inventários tem recebido atenção considerável dos pesquisadores nos últimos anos (Samanta e Bhowmick, 2010; Al-Khedhairi, 2010; Viji e Karthikeyan, 2016).

Deterioração é definido como um fenômeno físico que impede que um item seja usado para seu propósito original ou que resulta na diminuição de sua utilidade ou valor, como (i) a deterioração de alimentos perecíveis, frutas e vegetais; (ii) o esgotamento físico, como no furto

ou evaporação de líquidos voláteis, como gasolina, perfumes, álcool; (iii) deterioração como em substâncias radioativas, degradação, como em componentes eletrônicos ou perda de potência como em filmes fotográficos, medicamentos, fertilizantes, etc. (Kalam et al., 2010; Soni et al., 2010; Karmakar e Choudhury, 2010; Nagare e Dutta, 2012; Sharma e Singh, 2013).

Os produtos perecíveis têm perda contínua ou discreta de utilidade e, portanto, podem ter vida útil fixa ou aleatória. Os produtos com vida útil fixa possuem uma validade determinística, conhecida e definida (por exemplo, produtos farmacêuticos, embalagens de consumo e filmes fotográficos). Já para os produtos perecíveis com vida útil aleatória o tempo de deterioração é incerto, dependendo de fatores como a atmosfera de armazenamento, e são descartados quando estragam (por exemplo, frutas, vegetais, produtos lácteos, produtos de panificação etc.) (Nagare e Dutta, 2012). A maioria dos pesquisadores definem modelos que utilizam taxas de deterioração constante ou que sigam a distribuição de Weibull. A taxa de deterioração aumenta com a idade, ou seja, quanto mais tempo os itens permanecem sem uso, maior a taxa na qual eles deterioram (Samanta e Bhowmick, 2010; Al-Khedhairi, 2010; Viji e Karthikeyan, 2016).

Para produtos perecíveis, como produtos lácteos, itens de padaria, vegetais, frutas etc., observa-se que a idade do inventário tem um impacto negativo na confiança do consumidor por razões como (i) proximidade com datas de expiração, (ii) efeitos prejudiciais sobre a qualidade do produto, (iii) concepção geral de que um item não vendido por um longo período de tempo pode ser de qualidade inferior (Soni et al., 2010).

### **2.1.2. Modelagem matemática e técnicas estruturadas voltadas à redução do risco de obsolescência e deterioração de estoques**

A gestão de inventário é uma área complexa, demandando o desenvolvimento de sistemas inteligentes para auxiliar na tomada de decisões. Diferentes produtos estão associados a diferentes estruturas de demanda, demandando diferentes métodos de previsão e controle de estoque. Desta forma, é importante classificar os produtos em diferentes categorias e aplicar os métodos mais adequados de gestão para cada categoria. A maioria das regras de classificação utilizadas pelas empresas para atingir os níveis de serviço desejados envolve técnicas de previsão e controle de estoque, como a classificação ABC e as regras baseadas em valores de demanda (volumes de venda e preços de venda). A forma como esta atividade é executada tem consequências na gestão do estoque e na satisfação do cliente; logo, definir regras de classificação é um elemento fundamental dos sistemas inteligentes de gerenciamento de inventário. Entretanto, a categorização da demanda tem atraído pouco interesse acadêmico. Há na literatura uma quantidade considerável de pesquisas sobre a classificação de inventário e

métodos de previsão, porém, estas pesquisas não abordam a distinção entre diferentes padrões de demanda para orientar a previsão e controle de estoque (Boylan et al., 2008; Syntetos et al., 2010), ou mesmo o gerenciamento prático das operações de acordo com os processos de envelhecimento do inventário (Wu, 2013).

Segundo Kamau e Kagiri (2015), a contribuição dos sistemas de controle de estoques no desempenho operacional de uma organização é focada em benefícios financeiros e não financeiros, na eficiência dos procedimentos e na eficácia das atividades de suprimento. De acordo com Wu (2010), índices financeiros de empresas são utilizados para construção de modelos de previsão de falha desde a década de 1960. Huang et al. (2008) definem índices financeiros como ferramentas importantes para previsão de falhas de negócios e um dos principais insumos para desenvolver os modelos de previsão de falha. Dentre os muitos indicadores financeiros selecionados por Wu (2010) e Huang et al. (2008) para a construção de modelos de previsão de falhas nos negócios está a taxa de rotatividade de inventário (ITO - *Inventory Turnover Ratio*).

Song e Lau, 2004 recomendam que, quando a obsolescência é uma consideração importante no gerenciamento de estoques, seja utilizado um modelo matemático para o gerenciamento ou mitigação destes riscos. Para Whybark (2007), o gerenciamento de estoques sujeitos à obsolescência requer recursos sofisticados de processamento e comunicação de informações. Modelagens matemáticas para inventários geralmente incluem os três principais custos relacionados ao estoque: custo do excesso de inventário, da falta de inventário e do processo de compras. Porém, grande parte destas modelagens não inclui uma série de questões atuais e de crescente importância na gestão de estoques (Bonney e Jaber, 2011). Junior e Nocera (2014) afirmam que modelos de controle de inventário podem ser usados para tomada de decisão (por exemplo, de quanto comprar, produzir ou estocar) e que um estoque inadequado pode inviabilizar um negócio devido aos altos custos envolvidos. Com relação à redução de risco de obsolescência de inventário, a pesquisa de Van Jaarsveld e Dekker (2010) cita Song e Zipking (1993 e 1996) sobre os efeitos da obsolescência sobre a política de inventário, mostrando que uma economia significativa pode ser feita incluindo o risco de obsolescência na decisão de inventário; para tanto, os autores propõem um modelo computacional que implicitamente inclui um ambiente de demanda flutuante usando o processo de Poisson e uma cadeia de Markov de tempo contínuo. Beamon (1998) apresentou uma revisão da literatura sobre modelagem da cadeia de abastecimento multiestágio; dentre as pesquisas avaliadas pela autora, apenas o trabalho conduzido por Ichii et al. (1998) abordou a redução do estoque obsoleto através de um

modelo para determinar o nível econômico de estoque para determinados parâmetros de produção e transporte.

Por sua vez, Teunter et al. (2011) avaliaram a literatura disponível sobre demanda intermitente e risco de obsolescência, propondo um método de previsão da demanda intermitente com foco na redução do risco de obsolescência. Segundo Thummalappalli (2010), as organizações devem implementar medidas e métodos que possam ajudar os gerentes de inventário identificar o inventário excessivo e fazer uso deste estoque antes dele se transformar em obsoleto, visto que uma quantidade significativa de investimento pode ser salva eliminando estoques obsoletos e excessivos. Kholopane (2016) apresenta uma aplicação da ferramenta seis sigma integrada com os sistemas existentes de gestão de inventário para melhorar o controle de estoque e minimizar o risco de estoque obsoleto. Pingle (2015) propõe um método para gestão da obsolescência de inventário através da Teoria da Utilidade Multiatributo (MAUT - *Multi Attribute Utility Theory*), com intuito de obter a melhor estratégia de resolução da obsolescência. O autor cita ainda três categorias de gerenciamento do risco de obsolescência, sendo elas: (i) a gestão reativa, que trata o problema após o item tornar-se obsoleto; (ii) a gestão proativa, onde as ações são tomadas antes do item tornar-se obsoleto, e; (iii) a gestão estratégica, utilizada para o planejamento estratégico, otimização do ciclo de vida de produtos e desenvolvimento de negócios de longo prazo.

Com propósitos alinhados aos autores anteriores, Yang e Williams (2009) propõem uma metodologia para caracterizar as tendências futuras na geração de computadores obsoletos nos Estados Unidos a partir de dados históricos de vendas de novos computadores de 1978 a 2008, assumindo uma distribuição de vida útil e extrapolando a tendência de vendas históricas para o futuro usando um modelo logístico ajustado a modelos estatísticos. Na mesma linha, Zhang et al. (2011) apresentam um modelo para estimar o inventário futuro de cinco tipos de eletrodomésticos para efeitos de reciclagem (logística reversa) utilizando os dados disponíveis a partir do sistema estatístico chinês, o qual foi aplicado em Nanjing, China, para o período de 2009 a 2050. Sandborn et al. (2011) propõem uma metodologia para a geração de algoritmos que podem ser usados para prever as datas de obsolescência de componentes eletrônicos que não têm direcionamentos paramétricos evolutivos claramente definidos, com base no cálculo do tempo de vida de aquisição, utilizando bases de dados de eventos de obsolescência anteriores no planejamento de compras para produção de equipamentos e dispositivos eletrônicos. Já Wong et al. (2006) incluem o risco de obsolescência do inventário para avaliar a reatividade

das cadeias de suprimento voláteis e sazonais, não indicando, porém, métodos estruturados para prever o risco de obsolescência.

Syntetos et al. (2010) citam a importância de considerar a obsolescência do inventário em modelos de tomada de decisão e controle de estoques, ao passo que Jones e Tuzel (2013) exploram o efeito de diversos aspectos da gestão de inventário, incluindo o risco de obsolescência, e o custo de capital das empresas (principalmente a relação entre os prêmios de risco e o investimento em inventário). Xia e Xen (2011) consideram o risco de inventário um fator importante para a tomada de decisão em modelos de avaliação de risco de cadeias de suprimento (devido a longos ciclos logísticos, baixa qualidade e inventários inadequados). Kumar e Saranga (2010) revisam a literatura recente sobre o risco de obsolescência de componentes devido ao longo ciclo de vida de bens de capital. O método proposto utiliza técnicas de programação zero-um e de benefício marginal esperado, entre outras, para definir o tempo ótimo para o redesenho dos produtos (bens de capital), de forma a reduzir o risco de obsolescência de seus componentes. Nenes et al. (2010) incluem o risco de obsolescência devido ao excesso de inventário para evitar baixos níveis de atendimento aos clientes em seu trabalho sobre a gestão de inventários de múltiplos itens com demanda irregular, apresentando um sistema informatizado capaz de identificar – porém não prever – itens obsoletos. Song e Lau (2004) apresentam um modelo de inventário estocástico de revisão periódica com obsolescência súbita que permite a acumulação da demanda estocástica em cada período.

Battini et al. (2014) propõem um modelo de cálculo dos custos totais de abastecimento de um item específico com base no lote econômico de compra (EOQ – *Economic Order Quantity*), considerando, entre outros parâmetros, o risco de obsolescência do inventário, aplicando uma abordagem de contabilidade direta. Neste modelo, o inventário apresenta um risco de obsolescência ao final do ano expresso pela taxa de risco anual de obsolescência. Os itens obsoletos são posteriormente vendidos a empresas específicas de tratamento de resíduos para descarte a um preço inferior ao custo original de estoque. A diferença entre o custo original de estoque e o preço de venda para descarte é considerado como o custo interno da obsolescência. O modelo propõe um risco crescente de obsolescência à medida em que os lotes de compra aumentam. Porém, os autores recomendam que o desenvolvimento futuro da pesquisa é necessário, principalmente quanto à análise de sensibilidade em escala real das funções de custo, a fim de quantificar exatamente quando a abordagem contábil direta deve ser completamente substituída pelos outros métodos.

Pinçe e Dekker (2011) propõem um sistema de revisão contínua do inventário, incorporando o risco de obsolescência, para itens de baixo giro de inventário e alto valor agregado em situações de queda da taxa de demanda em um momento futuro conhecido. Este sistema altera a política de controle do inventário de forma a iniciar a remoção do estoque antes que a queda da demanda inicie. O sistema proposto, porém, tem como limitações o fato de não incluir tratativas para os estoques antes e após se tornarem obsoletos, além de não incluir a previsão (ou a incerteza) relativa ao tempo no qual o estoque virá a se tornar obsoleto.

Bartels et al. (2012) afirmam que o processo de gerenciamento de obsolescência (atividades que são realizadas para mitigar os efeitos da obsolescência) é uma atividade chave para manter a rentabilidade em sistemas de longo ciclo vida, e propõe a utilização do ciclo PDCA para que o plano de gerenciamento de obsolescência melhore continuamente. Os autores ainda apontam três grandes categorias de estratégias de gerenciamento de obsolescência, sendo elas: (i) reativa (ações são tomadas após determinado item tornar-se obsoleto); (ii) proativa (ações são tomadas antes de determinado item tornar-se obsoleto), e; (iii) estratégica (usada para planejamento estratégico, otimização do ciclo de vida e desenvolvimento de planos de negócios de longo prazo). Além de Bartels et al. (2012), Erlandsson & Duhan (2008) e Araújo et al. (2016) também sugerem a utilização do ciclo PDCA em processos de gestão de inventário.

Há pouca literatura disponível sobre gestão de estoques abordando os processos de envelhecimento do inventário (Wu, 2013), sendo que a maioria destes aborda o risco de deterioração do inventário (aplicável principalmente a itens perecíveis), como os listados por Goyal e Giri (2001), Bakker et al. (2012) e Janssen et al. (2016).

Há, porém, pesquisas abordando o envelhecimento do inventário sobre a ótica do risco de obsolescência. Wu (2013) propõe um modelo de previsão multiperíodo de baixa contábil do inventário que captura algumas características específicas da empresa, incluindo práticas contábeis, idade do inventário e estruturas de produto em empresas fabricantes de semicondutores, empregando cinco procedimentos heurísticos de tempo polinomial sequencial. O estudo mostra que para prevenir a baixa contábil de inventários é necessário focar na implantação do FIFO (*First-In First-Out*), na redução dos custos de manufatura e no monitoramento das mudanças na demanda de mercado. Chen et al. (2011) realizaram estudo similar na indústria de semicondutores, enfatizando que as características desta indústria resultam em altos riscos de excesso de capacidade e obsolescência tecnológica, aumentando a probabilidade de excesso de estoques e baixas contábeis de inventário. Li et al. (2014) propõe um sistema inteligente para facilitar o gerenciamento de dados que permite o monitoramento e



análise do envelhecimento do inventário com o objetivo de reduzir o excesso de estoque. A ferramenta proposta permite a visualização das distribuições de envelhecimento do inventário de um determinado item e a comparação das mudanças de envelhecimento do inventário atual e histórico. Westerman (2015) propõe o uso de um indicador da idade do inventário como forma de maximizar o capital de giro. Raza et al. (2017) citam o impacto negativo do envelhecimento do inventário em um estudo de caso na indústria automotiva.

Meng et al. (2014) apresentaram um modelo matemático estratégico e proativo de gerenciamento de obsolescência para sistemas de longa vida útil. O modelo proposto busca soluções ótimas para o problema de obsolescência de componentes, indicando o custo mínimo de obsolescência com base em um cronograma de gerenciamento que aponta o momento ótimo para o redesenho do produto. O modelo proposto apresentou melhores resultados comparado aos sistemas tradicionais (reativos) de gestão de inventários.

Fisher et al. (2001) propõem um modelo para otimização de estoques para o reabastecimento de produtos de moda de varejo determinando, para um ciclo de vida curto, as quantidades de pedidos iniciais e de reabastecimento de produtos de varejo que minimizam o custo de vendas perdidas, pedidos atrasados e estoques obsoletos através de um programa dinâmico estocástico de dois estágios.

Larson et al. (2011) conduziram um estudo com 290 empresas que apresentaram baixas contábeis de inventário pela primeira vez entre 2002 e 2004, onde as baixas contábeis de inventário representaram 3,7% dos ativos totais destas empresas, com impacto severo em sua performance operacional. O impacto econômico das baixas contábeis de inventário é tão significativo que as empresas precisam levar em conta tais eventos adversos potenciais ao tomar decisões de inventário. Por fim, Kaufmann e Gaeckler (2015) conduziram um estudo sobre o uso de PLS (*Partial Least Squares*) em 75 artigos publicados nas principais revistas de Gestão da Cadeia de Suprimentos (*Supply Chain Management*) de 2002 até 2013. O estudo indica o potencial de PLS nos processos de gestão da cadeia de suprimentos, mas também suas limitações. De acordo com este estudo, a aplicação da modelagem de equações estruturais (SEM - *Structural Equation Modeling*) na gestão da cadeia de suprimentos tem experimentado crescente popularidade nos últimos anos, e que, embora a maioria dos pesquisadores possuam uma boa compreensão básica das técnicas tradicionais à base de *Covariance-Based SEM* (CBSE), eles estão menos familiarizados com o uso adequado dos métodos PLS. Segundo os autores, o método PLS ganhou popularidade em várias disciplinas, incluindo a gestão da cadeia de suprimentos, devido às limitações do método CBSE e da adequação do PLS para estimar

modelos de pesquisa utilizando tamanhos de amostra consideravelmente menores. Dentre os artigos pesquisados pelos autores, apenas o trabalho desenvolvido por Claassen et al. (2008) apresenta uma aplicação de regressão PLS para planejamento de inventário gerenciado pelo fornecedor (VMI - *Vendor Managed Inventory*), porém nenhum dos estudos aborda o tema da redução do risco de obsolescência de inventário.

A maioria dos modelos de inventário na literatura baseia-se na suposição de vida útil infinita dos bens, no entanto, existem muitos bens que se deterioram e/ou se tornam obsoletos ao longo do tempo, os quais demandam modelos diferentes de gestão de inventário. Kalam et al. (2010) propõem uma política ótima que minimiza o custo associado ao inventário e à taxa de produção para um horizonte de tempo finito para itens que seguem a curva de deterioração de Weibull e possuem demanda e produção quadráticas. Soni et al. (2010) apresentam uma extensa revisão bibliográfica sobre abordagens orientadas quantitativamente para determinar o tamanho ideal do lote quando o fornecedor oferece um período de crédito para o varejista para liquidar suas contas. Nagare e Dutta (2012) apresentam em sua revisão de literatura diversos estudos sobre a relação da taxa de demanda de produtos perecíveis com a quantidade de estoque exibida no varejo, e propõem um modelo de inventário para produtos que deterioram continuamente com vida útil aleatória e demanda dependente do estoque exposto no varejo propondo uma condição de estoque zero no final do ciclo e mantendo um estoque de reserva para estimular a demanda. Viji e Karthikeyan (2016) apresentam um modelo para encontrar a quantidade ótima de produção em diferentes períodos para minimizar o custo total de estoque para três diferentes níveis de produção para itens com deterioração, e apresentam uma extensa revisão da literatura sobre gestão de itens sujeitos a deterioração, e cuja taxa de deterioração obedeça à distribuição de Weibull. Karmakar e Choudhury (2010) apresentam em sua pesquisa uma vasta revisão da literatura sobre modelos de inventário para deterioração de itens com escassez, afirmando que a literatura relacionada à deterioração de itens com escassez está dispersa, e que até a data de sua pesquisa não havia disponível nenhuma discussão detalhada e abrangente sobre esses modelos. Al-Khedhairi (2010) apresenta um sistema de controle ótimo de inventário de produção com itens que apresentam deterioração com o tempo seguindo dois parâmetros de distribuição exponencial generalizada. Chung et al. (2014) apresentam um novo modelo quantidade de produção econômica em sistemas de inventário considerando a deterioração de itens sob dois níveis de crédito comercial, no qual o fabricante oferece ao varejista um período de atraso permissível e, ao mesmo tempo, o varejista fornece um período de crédito comercial máximo para seus clientes em um sistema de cadeia de suprimentos composto por três estágios.

Tayal et al. (2014) apresentam um modelo para determinação do lote econômico de itens sujeitos a deterioração em ambientes com restrição de espaço de armazenagem. Sarkar et al. (2015) propõem um modelo que considera a demanda como uma função de tempo dentro do ciclo de vida dos produtos, considerando quatro tipos diferentes de funções de deterioração probabilística contínua. Sharma e Singh (2013) apresentam modelo de inventário de reversão parcial para itens sujeitos a deterioração considerando a taxa de demanda de estoque e preço em ambientes distorcidos.

## 2.2. FERRAMENTAS MULTIVARIADAS

A quantidade de informações disponíveis para tomada de decisão aumentou muito nos últimos anos e continuará aumentando nos anos que estão por vir, de forma ainda mais rápida, tornando mais complexas as pesquisas que fazem uso de ferramentas estatísticas. Uma grande parcela destas informações pode ser estudada através de técnicas estatísticas simples, porém, muitas demandam técnicas complexas que permitam a análise simultânea de mais de duas variáveis para converter as informações em conhecimento. O armazenamento e utilização destas informações para otimizar a tomada de decisão só é possível graças ao avanço da computação e redução do custo do armazenamento e processamento de dados, que tornou viável realizar análises estatísticas com diferentes modelos de técnicas multivariadas em ampla escala (Hair et al., 2009; Rencher, 2003; Vicini e Souza, 2005; Tabachnick e Fidell, 2007; Ayres et al., 2007; Liu et al., 1999; Bakke et al., 2008).

Os métodos estatísticos dividem-se em univariados, bivariados e multivariados, sendo que (i) os métodos univariados olham as variáveis de maneira isolada (existe uma única variável dependente, podendo haver mais de uma variável independente); (ii) o termo “estatística bivariada” se refere com frequência à análise de duas variáveis onde nenhuma delas é uma variável experimental independente, com intuito apenas de estudar a relação entre as variáveis (por exemplo, a relação entre renda e quantidade de educação), e; (iii) os métodos multivariados olham as variáveis de forma conjunta. O termo análise multivariada não é utilizado de forma consistente na literatura, dado que alguns autores utilizam o termo para descrever a análise de relações em geral entre duas ou mais variáveis (Vicini e Souza, 2005; Tabachnick e Fidell, 2007; Hair et al., 2009).

Embora a maioria das análises estatísticas seja multivariada por natureza, a dificuldade em realizar pesquisas complexas com análises univariadas tem feito com que os métodos estatísticos multivariados se tornem amplamente utilizados (Hair et al., 2009; Tabachnick e Fidell, 2007; Liu et al., 1999; Bakke et al., 2008). As primeiras análises multivariadas datam de

1886 com Francis Galton, passaram a receber maior atenção entre os acadêmicos no final da década de 1980, e desde o início da década de 1990 tem sido empregada em setores da indústria, principalmente por ser um conjunto de ferramentas muito eficaz para monitoramento de processos, modelagem e detecção de falhas. O monitoramento de desempenho em tempo real e a detecção precoce de desempenho dos processos ou de falhas nos equipamentos estão se tornando um pré-requisito para sustentar tanto a capacidade de produção quanto a rentabilidade das indústrias (Miletic et al., 2004; AlGhazzawi e Lennox, 2008; AlGhazzawi e Lennox, 2009).

Segundo Liland (2011), estatística multivariada é simplesmente a análise estatística de mais de uma variável estatística simultaneamente, sendo uma ampla disciplina incluindo muitos métodos gerais e especializados. Mingoti (2005) define a análise de dados multivariados como um conjunto de métodos aplicados em situações onde várias variáveis são medidas simultaneamente em cada elemento amostral. Para Johnson e Wichern (2007), os métodos multivariados compreendem as técnicas aplicadas em um conjunto de dados que incluem medições simultâneas de diversas variáveis. Já Hair et al. (2009) afirmam que o propósito da análise multivariada é medir, explicar e prever o grau de relacionamento entre as variáveis, de forma que a característica multivariada reside nas múltiplas combinações de variáveis, e não apenas no número de variáveis. Para AlGhazzawi e Lennox (2008), as ferramentas multivariadas são técnicas orientadas a dados que reduzem a dimensão dos dados do processo e extraem suas principais características e tendências, sendo capazes de fornecer uma abordagem robusta para a modelagem de processos e monitoramento de condições em tempo real.

Segundo Hair et al. (2009), muitas técnicas multivariadas são extensões de ferramentas de estatística univariada (estatística descritiva que permite a análise de cada variável separadamente) ou de estatística bivariada (incluem métodos de análises de duas variáveis, podendo ou não ser estabelecida uma relação de causa/efeito entre elas). A regressão simples (com uma variável preditiva) pode ser estendida para incluir múltiplas variáveis preditivas, assim como uma única variável dependente utilizada na análise de variância pode ser estendida para incluir múltiplas variáveis dependentes na análise multivariada de variância, fornecendo, desta forma, um meio de realizar em uma única análise (o que antes demandava múltiplas análises univariadas ou bivariadas para interpretação dos dados). Por outro lado, algumas técnicas multivariadas foram criadas especificamente para lidar com questões multivariadas, como a análise fatorial e a análise discriminante.

Embora os métodos multivariados derivem da estatística univariada e bivariada, alguns conceitos de grande relevância precisam ser entendidos para correta aplicação das técnicas. O primeiro conceito diz respeito à classificação das variáveis. As variáveis podem ser classificadas quanto ao seu tipo e natureza. Quanto ao tipo, as variáveis são, geralmente, classificadas como dependentes (ou variáveis de resposta) ou independentes (variáveis explanatórias). A variável de resposta é o objeto de interesse do pesquisador, na qual são esperadas alterações frente aos diferentes valores das variáveis independentes. Situações que apresentam apenas única variável dependente são estudadas a partir de técnicas estatísticas univariadas, enquanto situações com mais de uma variável dependente demandam técnicas estatísticas multivariadas para análise. As variáveis independentes são, geralmente, as variáveis medidas ou observadas, podendo ser aleatórias (medidas ou observadas) ou fixas (definidas pelo pesquisador). Quanto à natureza, as variáveis podem ser quantitativas ou qualitativas. As quantitativas (referentes a sequências numéricas) dividem-se em contínuas (valores em uma escala contínua, para as quais valores fracionais fazem sentido) e discretas (números inteiros, geralmente resultado de contagens). Já as variáveis qualitativas (ou categóricas) representam uma classificação, ou seja, não possuem valor quantitativo, e dividem-se em nominais (sem ordenação entre as categorias, por exemplo, cor dos olhos e sexo) e ordinais (as categorias são ordenadas, por exemplo, meses do ano e nível de escolaridade) (Hair et al., 2009; Melo e Hepp, 2008; Schielzeth, 2010).

O segundo é o conceito de *variate*, uma nova variável gerada através da combinação linear das variáveis originais com pesos determinados empiricamente. Enquanto as variáveis são definidas pelo pesquisador, os pesos são determinados pela técnica multivariada para atender a um objetivo específico. O resultado é uma combinação de todo o conjunto de variáveis que melhor atinja o objetivo da análise específica multivariada. Por exemplo, na regressão múltipla, a *variate* é determinada de forma a maximizar a correlação entre as múltiplas variáveis independentes e a única variável dependente. Na análise discriminante, a *variate* é formada de forma a criar pontuações (scores) para cada observação que maximizem a diferenciação entre grupos de observação. Já na análise fatorial, a *variate* é formada para melhor representar a estrutura subjacente dos padrões das variáveis representadas por sua intercorrelação. Uma *variate* de  $n$  variáveis ponderadas pode ser descrita matematicamente conforme a equação (1), na qual  $x_n$  é a variável observada e  $w_n$  é o peso determinado pela técnica multivariada (Hair et al, 2009).

$$\textit{variate} = w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n \quad (1)$$

O terceiro conceito é o de escala de medida (Hair et al., 2009). A análise de dados envolve a identificação e a medição da variação em um conjunto de variáveis, visto que o pesquisador não pode identificar a variação se esta não puder ser medida, e que a medição é importante para representar com precisão o conceito de interesse, tornando-se fundamental para a seleção do método de análise multivariada mais adequado à necessidade do pesquisador. Tabachnick e Fidell (2007) lembram que, ao aplicar técnicas estatísticas, é importante considerar o tipo de medição e a natureza da correspondência entre os números e os eventos que eles representam. Para Hair et al. (2009), as escalas de medida podem ser classificadas em duas categorias: métricas (quantitativos) ou não métricos (qualitativos). As escalas métricas são usadas quando as variáveis diferem em grandeza ou grau em um atributo particular, medindo a quantidade relativa ou grau em atributos envolvendo quantidade ou magnitude. As escalas métricas podem ser classificadas como escalas de intervalo (usa um ponto zero arbitrário) e escalas de proporção (utilizam um ponto zero absoluto, sendo a forma mais precisa de medição). As escalas não métricas expressam diferenças de tipo ou espécie, indicando a presença de ausência de uma característica ou propriedade, e dividem-se em nominais e ordinais. Segundo Agresti e Kateri (2011), a escala de medição é ordinal quando as categorias exibem uma ordem natural (por exemplo, variáveis de opinião com categorias de "discordo fortemente" ou "concordo fortemente"), e nominal quando não houver ordenação (por exemplo, na representação dos gêneros masculino e feminino, atribuir números para rotular ou identificar os gêneros como "1" para "masculino" e "2" para "feminino").

O quarto conceito é o de medição multivariada (Hair et al., 2009). Os erros de medição (grau em que os valores observados não são representativos dos valores verdadeiros devido a erros de coleta de dados ou imprecisão na medição) podem ser reduzidos através da validação dos dados, do aumento da confiabilidade das variáveis individuais ou da utilização da medição multivariada, que consiste na reunião de diversas variáveis em uma medida composta para representar um conceito. Por exemplo, ao medir a satisfação dos usuários quanto a um determinado resultado, ao invés de utilizar uma única questão (ou variável), combinar várias questões (ou variáveis) sobre satisfação em diferentes áreas da pesquisa e utilizar a média destes resultados.

Entre os diferentes métodos de análise de dados multivariados estão a análise fatorial (inclui a análise dos componentes principais – PCA, e a análise dos fatores comuns), a regressão múltipla e a correlação múltipla, a análise discriminante múltipla, a análise multivariada de variância e covariância (MANOVA, MANCOVA), a análise conjunta, a correlação canônica, a análise de

agrupamentos e o escalonamento multidimensional (Mingoti, 2005; Bakke et al., 2008). Hair et al. (2009) propõem uma classificação das técnicas multivariadas através da aplicação de três perguntas a respeito do objetivo de pesquisa, sendo elas: (i) as variáveis podem ser divididas entre dependentes e independentes?; (ii) caso sim, quantas variáveis são tratadas como dependentes em uma única análise?; e (iii) Como as variáveis dependentes e independentes são medidas? O Quadro 1 traz uma adaptação da classificação das técnicas multivariadas proposta por Hair et al. (2009).

TIPO DE RELACIONAMENTO EXAMINADO											
DEPENDÊNCIA						INTERDEPENDÊNCIA					
QUANTIDADE DE VARIÁVEIS PREVISTA						ESTRUTURA DAS RELAÇÕES					
Múltiplos relacionamentos de variáveis dependentes e independentes	Diversas variáveis dependentes em um único relacionamento			Uma variável dependente em um único relacionamento			Entre variáveis	Entre casos ou respondentes	Entre objetos		
	Escala de medição da variável dependente			Escala de medição da variável dependente					Medição dos atributos		
	Métrica		Não métrica	Métrica		Não métrica			Métrica		Não métrica
	Escala de medição da variável preditora										
Métrica		Não Métrica									
TÉCNICA MULTIVARIADA MAIS INDICADA						TÉCNICA MULTIVARIADA MAIS INDICADA					
Modelagem de equações estruturais	Análise de correlação canônica	Análise multivariada de variância	Análise de correlação canônica com variáveis mudas/fictícias	Regressão múltipla	Análise discriminante múltipla	Análise fatorial	Análise fatorial confirmatória	Análise de clusters	Dimensionamento multidimensional	Análise de correspondência	
				Análise Conjunta	Modelos de probabilidade linear					Dimensionamento multidimensional	

Quadro 1: Classificação das técnicas multivariadas

Fonte: Adaptado Hair et al. (2009)

Em função do objeto de estudo deste trabalho, as técnicas de regressão linear múltipla, regressão PLS e análise discriminante serão abordadas em detalhe nos próximos tópicos.

### 2.2.1. Condições para aplicação de técnicas multivariadas

As ferramentas multivariadas são metodologias empíricas de modelagem que dependem de dados, logo, a disponibilidade de dados suficientes para capturar as informações relevantes no processo é um ponto chave para definição do modelo estatístico. Porém, a quantidade de dados não pode ser definida de forma não empírica, mas sim estabelecida com base na experiência e na observação de implantações anteriores para que cada os objetivos da análise sejam atendidos. Porém, mais importante do que ter acesso a grandes quantidades de dados, é obter dados ou valores de sinais que sejam relevantes para análise do problema em questão. A experiência mostra que existem barreiras na implantação da estatística multivariada em ambientes industriais, tais como a má aceitação entre o pessoal da produção, falta de conhecimento da ferramenta, falta de treinamento, problemas de controle básicos não resolvidos, dificuldades no desenvolvimento e ajuste de sistemas de monitoramento, mudanças nos processos ao longo do tempo, complexidade de interpretação do sistema, informações imprecisas, falsos alarmes e falta de orçamento para operação e manutenção dos sistemas, que podem impactar na qualidade

dos dados e das análises (Miletic et al., 2004; AlGhazzawi e Lennox, 2008; AlGhazzawi e Lennox, 2009).

Alguns autores utilizam o termo análise multivariada apenas em situações nas quais todas as variáveis envolvidas apresentam uma distribuição normal multivariada (Hair et al., 2009). Johnson e Wichern (2007) citam que muitos métodos multivariados são baseados em um modelo de probabilidade conhecido como distribuição normal multivariada. Ayres et al. (2007) afirmam que um dos pré-requisitos dos testes estatísticos paramétricos é a distribuição normal das variáveis nas populações, ou seja, quando se retira uma amostra para esses modelos de testes supõe-se que as unidades do conjunto de dados a que pertencem apresentem distribuição normal. Tabachnick e Fidell (2007) citam que a propriedade crucial das variáveis para a aplicação de procedimentos multivariados é a forma da distribuição, sendo que variáveis contínuas não distribuídas de forma normal e variáveis dicotômicas com divisões muito desiguais entre as categorias apresentam problemas para várias das análises multivariadas. Para Rencher (2003), a grande motivação para o uso generalizado da distribuição normal multivariada é a sua rastreabilidade matemática, proporcionando a utilização de diversos procedimentos estatísticos disponíveis em softwares, principalmente devido às poucas opções de procedimentos não paramétricos disponíveis para classificação de vetores de observação de dados multivariados. Além de apresentar uma distribuição normal multivariada, Hair et al. (2009) afirmam que para a análise ser considerada de fato multivariada, todas as variáveis precisam ser aleatórias e inter-relacionadas de forma que seus diferentes efeitos não possam ser interpretados de forma isolada. Já Vicini e Souza (2005) enfatizam a necessidade da existência de uma estrutura de correlação entre as variáveis para que as técnicas de análise multivariada possam ser aplicadas ao conjunto de variáveis objeto da análise.

### **2.2.2. Regressão linear múltipla**

O problema de regressão, ou seja, de como modelar uma ou mais variáveis dependentes ( $y$ ) por meio de um conjunto de variáveis preditoras ou independentes ( $x$ ) é um dos problemas de dados analíticos mais comuns em ciência e tecnologia. Tradicionalmente, a modelagem de  $y$  por meio de  $x$  é feita usando métodos de regressão linear simples (SLR - *Simple Linear Regression* - apenas uma variável dependente e uma variável independente), regressão linear múltipla (MLR - *Multiple Linear Regression*, - uma variável dependente e várias variáveis independentes) ou regressão linear múltipla multivariada (várias variáveis dependentes e várias variáveis independentes). A regressão linear simples é uma ferramenta muito útil para prever uma resposta para uma única variável independente, porém, na prática a maioria das análises



contempla a utilização de mais de uma variável independente. A regressão linear múltipla atende bem às necessidades da maioria das análises com mais de uma variável independente, desde que estas sejam relativamente poucas e não correlacionadas e tem sido vastamente utilizada em ambientes de negócios e tomadas de decisão, incluindo previsão em geral, modelos de tomadas de decisão de consumidores, análise de satisfação em diversas fontes de informação, avaliação dos determinantes da eficácia de um programa ou mesmo para análise da viabilidade de um novo produto ((Wold et al., 2001; Rencher, 2003; Hair et al., 2009; Tabachnick e Fidell, 2007; Kettaneh et al., 2005; James et al., 2013).

Para Nathans et al. (2012), modelos de regressão podem ser usados para responder a três tipos de questões teóricas de pesquisa: (i) as combinações específicas de variáveis independentes podem prever ou explicar a variância na variável dependente? (ii) uma determinada variável específica de um conjunto de variáveis independentes é necessária para prever ou explicar a variância na variável dependente? (iii) as combinações específicas de variáveis independentes predizem ou explicam a variância na variável dependente?

Na regressão linear múltipla, procura-se minimizar a soma do desvio quadrado entre a resposta ajustada e a resposta verdadeira no espaço medido pelas variáveis explicativas (Liland, 2011). Neste processo, cada variável independente é ponderada pelo procedimento de análise de regressão, de forma a assegurar a máxima previsão a partir do conjunto de variáveis independentes. Os pesos (coeficientes) utilizados no processo de ponderação indicam a contribuição relativa de cada variável independente para a previsão (ou a influência de cada variável independente em contribuir para o processo de previsão), embora a correlação entre as variáveis independentes complique o processo interpretativo. A aplicação da técnica demanda: (i) a separação das variáveis dependentes das variáveis independentes; e (ii) que os dados sejam métricos ou tenham sido devidamente transformados através da codificação de variáveis fictícias (*dummy variables*) (Hair et al., 2009).

A vantagem da regressão linear múltipla sobre a regressão linear simples reside no fato de que, incluindo-se novas variáveis independentes na equação, pode-se aumentar o poder de predição do modelo quando comparado à utilização de apenas uma variável independente. Porém, a habilidade de uma variável independente adicional de aumentar o poder de previsão do modelo depende não apenas da correlação (força da associação entre duas variáveis métricas) entre a nova variável independente e a variável dependente, mas também da correlação entre a nova variável independente e as variáveis independentes já incluídas na função de regressão. A correlação entre duas variáveis independentes é denominada colinearidade, e a correlação entre

três ou mais variáveis independentes é chamada multicolinearidade. Para aumentar o poder de predição do modelo, o pesquisador deve procurar por variáveis independentes com baixa colinearidade ou multicolinearidade com as demais variáveis independentes, mas com alta correlação com a variável dependente. Entretanto, um modelo de regressão é extremamente sensível à combinação de variáveis nele incluída, visto que a importância aparente de determinada variável independente em um modelo depende das demais variáveis independentes incluídas na análise: se a variável independente analisada é a única a representar determinada característica da variável dependente esta parecerá mais importante, ao passo que se esta mesma variável independente é apenas uma de várias que avaliam a mesma característica da variável dependente ela geralmente parecerá menos importante. Na imensa maioria das aplicações reais existe algum grau de colinearidade entre as variáveis independentes, sendo que, mais comumente, a colinearidade é intrínseca (as variáveis colineares são manifestações diferentes do mesmo processo subjacente). A colinearidade perfeita ocorre quando as variáveis independentes são funções lineares exatas um do outro, o que configura um caso de erro de modelo onde uma das variáveis precisa ser omitida. Como regra, o conjunto ideal de variáveis independentes é o menor conjunto confiável, não correlacionado, que cobre as principais características da variável dependente (Hair et al., 2009; Tabachnick e Fidell, 2007; Dormann et al., 2013)

Liland (2011) observa que, desde que o número de observações seja maior do que o número de variáveis explicativas, e desde que estas variáveis não sejam multicolineares, a regressão linear múltipla é estável. Já Tabachnick e Fidell (2007) alertam que a análise de regressão revela relações entre as variáveis, o que não implica em afirmar que estas relações sejam causais, visto que a demonstração da causalidade é um problema lógico e experimental, e não estatístico. Uma relação aparentemente forte entre as variáveis pode resultar de diversas fontes, incluindo a influência de outras variáveis não incluídas no modelo de regressão.

O modelo de regressão linear com uma única resposta é descrito por Rencher (2003), Hair et al. (2009), Johnson e Wichern (2007), James et al. (2013) e Tabachnick e Fidell (2007) conforme a equação (2), onde  $y'$  é o valor previsto de  $y$  (variável dependente),  $\beta_0$  é o valor de  $y'$  quando todos os  $x$  forem igual a zero,  $\beta_1$  a  $\beta_k$  representam os coeficientes de regressão e  $x_1$  a  $x_k$  são as variáveis independentes e  $\varepsilon$  é o erro de predição (residual).

$$y' = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (2)$$

Esta equação assume ainda que nenhuma condição adicional é necessária para prever  $y$ , e que toda variação restante em  $y$  é puramente aleatória e imprevisível (Rencher, 2003; Johnson e Wichern, 2007).

Rencher (2003) e Johnson e Wichern (2007) mostram que com  $n$  observações independentes sobre  $y$  e os valores associados de  $x$ , expressando cada  $y$  em uma amostra de  $n$  observações como uma função linear de  $x$ , o modelo completo apresenta-se conforme descrito na equação (3).

$$\begin{aligned} y'_1 &= \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \cdots + \beta_k x_{1k} + \varepsilon \\ y'_2 &= \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \cdots + \beta_k x_{2k} + \varepsilon \\ &\vdots \\ y'_n &= \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \cdots + \beta_k x_{nk} + \varepsilon \end{aligned} \quad (3)$$

Tabachnick e Fidell (2007) mostram que os coeficientes de regressão que melhor se ajustam ao modelo produzem uma equação de predição para a qual as diferenças quadradas entre  $y$  e  $y'$  estão em seu valor mínimo ( $[y - y']^2$ ), o que é denominado solução de mínimos quadrados (*least squares*). Hair et al. (2009), da mesma forma, citam que o procedimento de mínimos quadrados, o qual é utilizado tanto na regressão simples quanto na regressão múltipla, estima os coeficientes de regressão de forma a minimizar a soma do quadrado residual.

Testes estatísticos podem ser utilizados para avaliar a relevância das variáveis independentes na predição das variáveis dependentes. Dentre tais testes, destaca-se o cálculo da função estatística  $F$  (*F-statistic*), sendo que quando, há relação entre a resposta e os preditores, é esperado um valor  $F$  maior do que 1; quando não há relação entre a resposta e os preditores, espera-se um valor  $F$  próximo a 1 (James et al., 2013). Segundo Mário (2002), a função estatística  $F$  é um teste de hipóteses que verifica se os regressores têm ou não relação com a variável dependente objeto da análise, desde que as amostras sejam aleatórias, independentes e extraídas de uma população normal, e que as populações tenham variâncias iguais.

O cálculo da função estatística  $F$  é realizado conforme as equações (4), (5) e (6) onde  $y'$  é o valor previsto de  $y$ ,  $TSS$  é a soma total dos quadrados (*Total Sum of Squares* - variância total na resposta  $y$ , podendo ser interpretado como a quantidade de variabilidade inerente à resposta antes da regressão ser realizada),  $RSS$  é a soma total dos quadrados residuais (*Residual Sum of Squares* - diferença entre o valor da resposta observada e o valor da resposta prevista pelo

modelo linear),  $n$  é o número de observações e  $p$  é o número de variáveis independentes (James et al., 2013; Mário, 2002).

$$F = \frac{(TSS-RSS)/p}{RSS/(n-p-1)} \quad (4)$$

$$TSS = \sum (y_i - \bar{y})^2 \quad (5)$$

$$RSS = \sum (y_i - \hat{y}_i)^2 \quad (6)$$

Após o cálculo de  $F$  e assumindo-se que há variáveis independentes úteis para previsão da variável dependente, parte-se para a análise da utilidade das variáveis independentes  $x$  para previsão da variável dependente  $y$ . É possível que todas as variáveis independentes estejam associadas com a resposta; porém, é mais comum que a resposta esteja relacionada apenas a um subconjunto das variáveis independentes. A tarefa de determinar quais variáveis independentes estão associadas com a resposta, de modo a definir um modelo envolvendo apenas estas variáveis independentes, é chamada de seleção de variáveis.

Com relação à precisão da previsão, James et al. (2013) afirmam que os dois métodos mais comuns para tal mensuração são o  $RSE$  e o coeficiente de determinação  $R^2$ . O erro padrão residual ( $RSE$  - *Residual Standard Error*) é uma estimativa do desvio padrão do erro de predição (residual), ou seja, é a quantidade média que a predição vai desviar do valor verdadeiro. Em geral, o  $RSE$  é descrito conforme a equação (7), onde  $p$  é o número de variáveis independentes e  $RSS$  é a soma total dos quadrados residuais (James et al., 2013).

$$RSE = \sqrt{\frac{1}{n-p-1} RSS} \quad (7)$$

O  $RSE$  fornece uma medida absoluta da falta de ajuste do modelo aos dados, porém, como é expresso em unidades de  $y$ , nem sempre é claro o que constitui um bom  $RSE$ . Por outro lado, o coeficiente de determinação  $R^2$  fornece uma medida alternativa de ajuste, tomando a forma de uma proporção (a proporção de variância explicada), assumindo um valor entre 0 e 1 independente da escala de  $y$ . Um valor de  $R^2$  próximo de 1 indica que o modelo explica uma grande porção da variância na variável de resposta (James et al., 2013). Muitos pesquisadores utilizam o coeficiente de determinação  $R^2$  (variando de 0 a 1) para quantificar o ajuste dos modelos regressão em regressões lineares múltiplas, ANOVA (*analysis of variance*), ANCOVA (*analysis of covariance*) e modelos lineares generalizados. Como  $R^2$  é unitário e adimensional, seu conceito é intuitivo e extremamente útil como um índice sumário para modelos estatísticos, visto que permite avaliar objetivamente o ajuste de modelos e comparar

os valores de  $R^2$  entre os estudos, por exemplo, de modelos com as mesmas respostas (Nakagawa e Schielzeth, 2013). O coeficiente de determinação  $R^2$  é uma medida para quantificar o grau de associação linear entre variáveis independentes e dependentes em na regressão linear, visto que pode ser interpretado como a fração de variação da resposta que é explicada pela relação de regressão (Yao et al., 2005).

Tabachnick e Fidell (2007) e Hair et al. (2009) apresentam de forma detalhada os conceitos envolvidos no processo de mínimos quadrados. Antes de estimar a regressão, é necessário definir a linha de base a partir da qual será comparada a habilidade de predição do modelo que está sendo desenhado. A linha de base deve representar a melhor previsão sem utilizar nenhuma variável independente, o que, em análise de regressão, é a simples média das variáveis independentes. Porém, há dois problemas principais com a utilização da média das variáveis independentes para predição: (i) a média não irá prever perfeitamente cada valor das variáveis independentes; e (ii) a observação dos erros na predição das variáveis dependentes através da média das variáveis independentes soma zero. Uma saída para estes problemas é elevar cada erro ao quadrado e somar os resultados obtidos. A soma dos quadrados de regressão é a porção da variação em  $y$  que é explicada pela utilização das variáveis independentes como predictoras, ou seja, é a soma das diferenças dos quadrados entre o previsto em  $y'$  e a média de  $y$ . Já a soma de quadrados residuais é a soma das diferenças dos quadrados entre os valores observados de  $y$  e as previsões do modelo  $y'$ , e representam os erros na previsão. A correlação múltipla é a correlação entre os valores previstos e os valores obtidos de  $y$ , e a correlação múltipla ao quadrado ( $R^2$ ) é a proporção da soma dos quadrados de regressão na soma total dos quadrados para  $y$ , ou seja, é a proporção de variação na variável dependente que é previsível a partir da melhor combinação linear das variáveis independentes. O  $R^2$  também pode ser observado nas correlações entre cada uma das variáveis independentes e a variável dependente: a correlação múltipla ao quadrado é a soma, através de todas as variáveis independentes, do produto da correlação entre a variável dependente, as variáveis independentes e o coeficiente de regressão (padronizado) para a variável independente. A padronização do coeficiente de regressão é necessária visto que a correlação é calculada diretamente sobre os dados, e pode ser obtida através da inversão da matriz de correlações entre as variáveis independentes, multiplicando pela matriz inversa de correlações entre a variável dependente e as variáveis independentes. Uma vez que os coeficientes de regressão padronizados estão disponíveis, eles são utilizados para escrever a equação para os valores previstos de  $y'$ .

O coeficiente de determinação  $R^2$  é representado pela equação (8), sendo que  $SS_r$  representa a soma dos quadrados da diferença entre a média da variável dependente e os valores estimados para todas as observações,  $SS_e$  representa a soma dos quadrados dos resíduos para todas as observações e  $SY_y$  representa a soma dos quadrados totais de  $y$  (Ferrer, et al., 2008; Masiero e Anzanello, 2011; Nakagawa e Schielzeth, 2013; James et al., 2013).

$$R^2 = \frac{SS_y}{SY_y} = 1 - \frac{SS_e}{SY_y} \quad (8)$$

Diversos autores afirmam que coeficiente de determinação  $R^2$  deve apresentar algumas propriedades específicas para que sejam utilizados em modelos de regressão, as quais estão relacionadas no Quadro 2.

PROPRIEDADES DO $R^2$ PARA MODELOS DE REGRESSÃO	
1	$R^2$ deve ter utilidade como medida adequação geral do modelo e deve ser de fácil interpretação
2	$R^2$ deve ser adimensional
3	$R^2$ deve variar de 0 a 1, sendo zero a ausência total de ajuste e 1 uma adequação perfeita do ajuste ao modelo
4	$R^2$ deve ser suficientemente geral para ser aplicável a qualquer tipo de modelo
5	Os valores de $R^2$ não devem ser afetados por diferentes técnicas de ajuste do modelo
6	Os valores de $R^2$ para diferentes modelos ajustados ao mesmo conjunto de dados devem ser diretamente comparáveis
7	Os valores relativos de $R^2$ devem ser comparáveis aos de outros métodos válidos de ajuste da regressão
8	Todos os resíduos (positivos e negativos) devem ser ponderados igualmente pelo $R^2$
9	O valor de $R^2$ não deve diminuir à medida em que novas variáveis independentes são adicionadas
10	O valor de $R^2$ baseado na soma residual de quadrados deve coincidir com o valor de $R^2$ baseado na soma de quadrados explicada
11	Os valores de $R^2$ e a significância estatística dos parâmetros de declive devem mostrar correspondência
12	O valor de $R^2$ deve ser interpretável em termos do conteúdo de informação dos dados

Quadro 2: Propriedades do  $R^2$  para modelos de regressão

Fonte: Adaptado de Orelien e Edwards (2008); Nakagawa e Schielzeth (2013)

O  $R^2$  ajustado é uma abordagem popular para a seleção entre um conjunto de modelos que contêm diferentes números de variáveis. Como o  $R^2$  ajustado leva em consideração o número de variáveis independentes incluídas na equação de regressão e o tamanho da amostra, embora o  $R^2$  sempre aumente se forem adicionadas mais variáveis ao modelo, o  $R^2$  ajustado pode cair se as variáveis independentes acrescentadas tiverem pouco poder explicativo ou se os graus de liberdade se tornarem demasiadamente pequenos. O  $R^2$  ajustado apresenta-se conforme a equação (9), onde RSS é a soma total dos quadrados residuais (*Residual Sum of Squares*), TSS é a soma total dos quadrados (*Total Sum of Squares*),  $n$  é o número de observações e  $p$  é o número de variáveis independentes (Hair et al., 2009; James et al., 2013).

$$R^2 \text{ ajustado} = \frac{RSS/(n-p-1)}{TSS/(n-1)} \quad (9)$$

Um grande valor de  $R^2$  ajustado indica um modelo com um pequeno erro de previsão. Isto ocorre porque, uma vez que todas as variáveis corretas tenham sido incluídas no modelo, a

adição de variáveis de ruído adicionais resultará numa pequena diminuição no RSS e, conseqüentemente, uma diminuição no  $R^2$  ajustado. Logo, teoricamente, o modelo com o maior  $R^2$  ajustado terá apenas variáveis corretas e sem variáveis de ruído (James et al., 2013).

Para James et al. (2013), em geral, determinar o que é um bom valor para o coeficiente  $R^2$  dependerá da aplicação. Em certos problemas da física, por exemplo, é possível conhecer se os dados realmente provêm de um modelo linear com um pequeno erro residual, esperando-se, neste caso, um valor  $R^2$  extremamente próximo de 1. Por outro lado, em aplicações típicas de análises biológicas, psicológicas ou de marketing, o modelo linear é geralmente uma aproximação pouco precisa dos dados, e os erros residuais devidos a outros fatores não medidos são muitas vezes muito grandes, sendo esperado um valor de  $R^2$  bem abaixo 1.

Para contornar esta dificuldade, várias técnicas estatísticas foram desenvolvidas para determinar as contribuições das variáveis independentes para os modelos de regressão múltipla, fornecendo diferentes métodos de classificar as contribuições das variáveis independentes individuais para o  $R^2$ , ou particionando o  $R^2$  nas contribuições de variância únicas e compartilhadas das variáveis independentes. Entre estas técnicas estão os pesos  $\beta$ , a medida de produto (ou medida de Pratt), o coeficiente de estrutura, os coeficientes de comunidade, a análise de dominância, os pesos relativos, a correlação de ordem zero, a análise de semelhanças e as correlações semiparciais quadradas (Nathans et al., 2012).

Segundo Grömping (2006), a determinação da importância relativa (quantificação da contribuição de uma variável independente individual para um modelo de regressão múltipla) em modelos lineares é relativamente simples, desde que as variáveis independentes não sejam correlacionadas. Porém, em um conjunto de dados com predominância de dados observacionais, as variáveis independentes são tipicamente correlacionadas, dificultando a interpretação do coeficiente de determinação  $R^2$  na determinação da importância das variáveis independentes. Nimon e Osvald (2013) citam como métricas e técnicas igualmente apropriadas para avaliar a importância relativa das variáveis preditoras de forma consistente com os objetivos de pesquisa os pesos de regressão, os coeficientes de correlação de ordem zero, os coeficientes de estrutura, as medidas de produto, os pesos relativos, a regressão de todos os subconjuntos possíveis, os pesos de dominância e os coeficientes de uniformidade.

A decisão entre utilizar o coeficiente  $R^2$  ou outros métodos de ajuste do modelo de previsão depende da precisão e da interpretabilidade do modelo desejada pelo pesquisador. Quanto à precisão, os autores consideram que o  $R^2$  leva a uma alta precisão de resposta quando a relação

entre a resposta e os preditores for aproximadamente linear e o número de observações ( $p$ ) for muito maior que o número de variáveis ( $n$ ). Por outro lado, quando  $n$  não é muito maior do que  $p$  pode haver muita variabilidade no ajuste dos mínimos quadrados, resultado em previsões com baixa precisão em observações futuras não incluídas na construção do modelo. Nas situações onde  $p$  é menor do que  $n$  a variância será infinita e o método não poderá ser aplicado. Quanto à interpretabilidade, é comum que algumas das variáveis utilizadas em um modelo de regressão múltipla não estejam associadas à resposta, e sua manutenção leva a um nível de complexidade desnecessária no modelo resultante, logo, a remoção destas variáveis (definindo estimativas de coeficientes correspondentes a zero) conduz a um modelo de mais fácil interpretação. O método dos mínimos quadrados, porém, não é adequado para produzir estimativas de coeficientes correspondentes a zero, demandando a utilização de outras abordagens para excluir variáveis irrelevantes de um modelo de regressão múltipla (James et al., 2013).

### 2.2.3. Regressão PLS

O método *Partial Least Squares* (PLS) é uma generalização da regressão linear múltipla (MLR) que, ao contrário da MLR, pode analisar dados altamente colineares, ruidosos e numerosos, além de modelar simultaneamente várias variáveis de resposta (Wold et al., 2001; Höskuldsson, 2001; Zimmer e Anzanello, 2014). A PLS atende a uma ampla classe de métodos para modelagem das relações entre conjuntos de dados observados por meio de variáveis latentes, compostos por técnicas de regressão, classificação, redução de dimensão e modelagem, os quais partem do pressuposto de que os dados observados são gerados por um sistema ou processo que é acionado por um pequeno número de variáveis latentes (Rosipal e Krämer, 2006).

Os métodos PLS são uma família de algoritmos de mínimos quadrados que se estendem da análise de componentes principais (PCA - *Principal Component Analysis*) à análise de correlação canônica (Henseler et al., 2009). Diferentes algoritmos PLS foram propostos para aplicações específicas, fazendo com que o termo "PLS" se tornasse demasiadamente generalizado, gerando alguma confusão na terminologia utilizada para nomear corretamente cada um destes algoritmos, principalmente com relação aos métodos PLS *Regression* (PLSR) e PLS-*Path Modeling* (PLS-PM) (Tenenhaus et al., 2005; Mateos-Aparicio, 2011; McIntosh et al., 2014; Marcoulides et al., 2009). Situações nas quais os modelos PLS são demasiadamente complexos para interpretação útil em relação à predição não são raros. Nestes casos, as análises devem ser baseadas em estratégias de modelagem alternativas ou em alguma modificação apropriada do algoritmo PLS original, incluindo, por exemplo, abordagens para remoção de variáveis independentes irrelevantes através de métodos de seleção de variáveis (Indahl, 2005).



O método PLS foi desenvolvido nas décadas de 1960 e 1970 por Herman O. A. Wold para a modelagem de conjuntos de dados com problemas de condicionamento no ramo da econometria. Inicialmente, Wold apresentou um processo iterativo usando mínimos quadrados para estimativa de modelos simples e com múltiplos componentes denominados NILES (*Non-linear Iterative Least Squares*), o qual evoluiu nos próximos anos para o modelo chamado NIPALS (*Non-linear Iterative Partial Least Squares*), capaz de calcular os componentes principais com uma sequência iterativa de regressões simples usando o método dos mínimos quadrados. Na década de 1970, Wold desenvolve o PLS (inicialmente conhecido como NIPALS para mínimos quadrados), adequado à modelagem de dados com variáveis latentes. Já nos anos 1980, o modelo PLS foi modificado por Svante Wold e Harald Martens para melhor atender os dados da ciência e tecnologia, e demonstrou ser útil para lidar com conjuntos de dados complexos. Na sequência, outros modelos foram propostos com base no PLS, como o SIMPLS, o PLS1 e o PLS2 (Wold et al., 2001; Geladi e Kowalski, 1986; Kaufmann e Gaeckler, 2015; Chun e Keles, 2010; Pirouz, 2006; Boulesteix e Strimmer, 2007; Abdi e Williams, 2013; Tenenhaus et al., 2005; Mateos-Aparicio, 2011; Indahl, 2005). Desde então, modelos baseados em PLS têm sido usados por um número crescente de pesquisadores em aplicações distintas como gerenciamento estratégico, sistemas de gerenciamento de informações, comportamento organizacional e marketing (Henseler et al., 2009; McIntosh et al., 2014).

Para Wold et al. (2001) a regressão PLS relaciona a matriz  $X$  (variáveis de previsão) à matriz  $Y$  (variáveis dependentes), gerando um conjunto de parâmetros que fornecem informações sobre a estrutura e o comportamento de  $X$  e de  $Y$ . Para Miletic et al. (2004), a regressão PLS é um método baseado em projeção, que emprega explicitamente as estruturas de covariância entre os elementos de  $X$  para aqueles de  $Y$ , e os de  $X$  para  $X$ , e de  $Y$  para  $Y$ , produzindo estimativas mais estáveis dado que a correlação entre as variáveis modeladas foi levada em consideração na construção do modelo. AlGhazzawi e Lennox (2009) afirmam que a regressão PLS é uma ferramenta que pode ser aplicada sempre que as variáveis possam ser particionadas em valores de causa ( $x$ ) e efeito ( $y$ ), sendo comumente usada em preferência a algoritmos de identificação alternativos tais como regressão linear múltipla (MLR) para desenvolver modelos conduzidos por dados, tendo como vantagem a capacidade de produzir modelos precisos e robustos em situações onde existem altos níveis de correlações entre as variáveis de causa.

O algoritmo PLS é, essencialmente, uma sequência de regressões em termos de vetores de peso, e seu algoritmo básico inclui três fases. A fase 1 consiste na estimativa iterativa das pontuações das variáveis latentes, fase na qual um processo iterativo de quatro passos é repetido até que

seja obtida a convergência: (i) aproximação externa da pontuação das variáveis latentes (os modelos externos das variáveis latentes são calculados como combinações lineares de seus respectivos indicadores); (ii) estimativa dos pesos internos (os pesos dos modelos internos são calculados para cada variável latente, a fim de refletir o quão fortemente as outras variáveis latentes estão conectados a ela); (iii) aproximação interna da pontuação das variáveis latentes (os modelos internos das variáveis latentes são calculados como combinações lineares dos respectivos modelos externos de suas respectivas variáveis latentes adjacentes, usando os pesos interiores previamente determinados); e (iv) estimativa dos pesos externos (os pesos dos modelos externos são estimados, no modo reflexivo, como as covariâncias entre o modelo interno de cada variável latente e seus indicadores, ou, no modo formativo, como os pesos resultantes da regressão por mínimos quadrados do modelo interior de cada variável latente nos seus indicadores). Os quatro passos da fase 1 são repetidos até que a mudança de pesos exteriores entre duas iterações caia abaixo de um limite predefinido. A fase 2 consiste na estimativa de pesos/cargas exteriores e coeficientes de caminho, e a fase 3 na avaliação dos parâmetros de localização (Henseler et al., 2009).

Os fundamentos matemáticos da regressão PLS são detalhados por Wold et al. (2001), Anzanello (2013) e Zimmer (2012), e AlGhazzawi e Lennox (2009), como segue: considere uma matriz  $X$ , de dimensão  $K \times N$ , e uma matriz  $Y$ , de dimensão  $M \times N$  (sendo  $K$  o número de variáveis de processo,  $M$  o número de variáveis de resposta e  $N$  o número de observações); o vetor  $x_i$  ( $x_{i1}, x_{i2}, \dots, x_{ik}$ ) representa a observação  $i$  para cada variável de processo  $k$ , enquanto o vetor  $y_i$  ( $y_{i1}, y_{i2}, \dots, y_{im}$ ) representa a observação  $i$  para cada variável de resposta  $m$ ; a regressão PLS gera  $a$  variáveis latentes (combinações lineares)  $t_a$  ( $a = 1, 2, \dots, a$ ) a partir das variáveis originais; as combinações são ortogonais entre si e usadas com propósitos de predição e controle de processo; a definição do número de componentes a serem mantidos no modelo se dá através da avaliação da significância de cada componente em termos de predição, interrompendo-se a inclusão de componentes no modelo quando os mesmos deixam de ser significativos. As variáveis latentes  $t_a$  são combinações lineares independentes das variáveis  $x$  com coeficientes  $w_a$  ( $w_{1a}, w_{2a}, \dots, w_{ka}$ ), conforme a equação (10):

$$t_{ia} = w_{1a}x_{i1} + w_{2a}x_{i2} + \dots + w_{ka}x_{ik} = w'_a x_i \quad (10)$$

O vetor  $w_a$  representa o peso da variável de processo  $k$  no componente  $a$ , sendo importante ressaltar que também leva em conta a influência das variáveis de produto. As variáveis latentes  $u_a$  ( $a = 1, 2, \dots, a$ ) são combinações lineares das variáveis  $y$ . O vetor  $c_a$  ( $c_{1a}, c_{2a}, \dots, c_{ma}$ ) representa o peso de cada variável de produto  $m$  no componente  $a$ , conforme a equação (11):

$$u_{ia} = c_{1a} + y_{1x} + c_{2a} + y_{2x} + \dots + c_{ka} + y_{kx} = c'_a y_i \quad (11)$$

Os vetores  $w_a$  e  $c_a$  são escolhidos de forma a maximizar a covariância entre os componentes  $t_a$  e  $u_a$  (os quais concentram informações sobre as observações e suas semelhanças em relação ao modelo), e fornecem informações sobre como as variáveis se combinam para formar a relação quantitativa entre X e Y, apontando as variáveis  $x$  de maior relevância (maiores valores de  $w_a$ ). Multiplicando o vetor de cargas das variáveis de processo  $p_a$  ( $p_{1a}, p_{2a}, \dots, p_{ka}$ ), pelo vetor  $t_a$ , pode-se reconstituir a matriz X com valores reduzidos dos resíduos  $e_{ik}$ , conforme a equação (12), cuja representação matricial é  $x = tp' + e$ .

$$x_{ik} = \sum_a t_{ia} p_{ak} + e_{ik} \quad (12)$$

A predição das variáveis de resposta  $y$  pode ser obtida pela multiplicação de  $u_a$  pelos coeficientes  $c_a$ , conforme a equação (13), cuja representação matricial é  $y = uc' + g$ .

$$y_{im} = \sum_a u_{ia} c_{am} + g_{im} \quad (13)$$

A equação (14) apresenta os coeficientes da regressão PLS, cuja representação matricial é  $b = w * c'$ . Os resíduos da predição são representados por  $w^*_{ka} = w_{ka} (p_{ka} w_{ka})^{-1}$ .

$$b_{mk} = \sum_a c_{ma} w^*_{ka} + f_{im} \quad (14)$$

Substituindo-se as equações anteriores chega-se ao formato tradicional para o modelo de regressão proposto por Wold et al. (2001), conforme a equação (15), cuja representação matricial é  $y = xb + f$ .

$$y_{im} = \sum_a b_{mk} x_{ik} + f_{im} \quad (15)$$

Alguns autores, porém, ressaltam que, ao analisar o grande número de variáveis atualmente coletadas de processos industriais, é comum constatar que essas variáveis estão localizadas em diferentes intervalos numéricos. A gama numérica de uma dada variável influencia a sua variância (ou seja, uma grande gama numérica implica uma grande variância), e os métodos PLS são dependentes da variância. Portanto, é geralmente necessário colocar os dados em uma mesma escala para torná-los mais adequados para a análise (Ferrer, et al., 2008).

Poucas técnicas são versáteis o suficiente para serem aplicadas em uma ampla gama de problemas e lidar com cenários de estrutura de dados diferentes, típicas dos processos modernos complexos. A grande força dos modelos PLS repousa no fato de que a mesma ferramenta pode ser usada em diferentes contextos, podendo ser aplicada com sucesso para a resolução de problemas em ambientes altamente competitivos e exigentes (Ferrer et al., 2008).

#### 2.2.4. Análise discriminante

Embora a análise de regressão múltipla seja a técnica multivariada mais amplamente utilizada (principalmente pela habilidade em prever e explicar variáveis métricas), situações onde as variáveis dependentes não são métricas demandam técnicas apropriadas de análise. A análise discriminante trata especificamente das situações onde há uma única variável dependente não métrica e um conjunto de variáveis independentes métricas, buscando a previsão e explicação dos relacionamentos que afetam a categoria na qual o objeto de análise está inserido ou a identificação do grupo ao qual o objeto de análise pertence. Por exemplo, determinar o porquê de determinado indivíduo ser ou não cliente de um estabelecimento, classificar alunos quanto aos interesses vocacionais ou determinar a categoria de risco de crédito para determinado cliente (Hair et al., 2009; Hendriks et al., 2011; Gimenes e Uribe-Opazo, 2001).

Johnson e Wichern (2007) afirmam que a análise discriminante é uma técnica multivariada de natureza explicativa, aplicada na separação de conjuntos distintos de objetos ou observações e na alocação de novos objetos ou observações em grupos previamente definidos. Segundo Mário (2002), a análise discriminante é uma ferramenta estatística multivariada utilizada para fazer inferência sobre uma determinada população observada, dividida em grupos, através de uma regra matemática que sirva para classificação de uma nova observação em um dos grupos previamente estabelecidos. Tabachnick e Fidell (2007) apontam que o objetivo principal da análise discriminante é prever a associação de grupo a partir de um conjunto de preditores e encontrar funções de classificação para prever a adesão ao grupo. Para Hair et al. (2009), a análise discriminante pode ser considerada tanto uma técnica de análise de tipo de perfil quanto uma técnica analítica de previsão.

As duas formas mais populares de análise discriminante são a análise discriminante linear (LDA – *Linear Discriminant Analysis*) e a análise discriminante quadrática (QDA – *Quadratic Discriminant Analysis*). Os termos linear e quadrático referem-se às fronteiras entre grupos (populações ou amostras de populações) vizinhos, que são linhas/(hiper) planos ou curvas/(hiper) planícies curvas. A análise discriminante linear (LDA) tem sido um dos métodos mais populares utilizados em problemas de classificação. Sua ideia básica é projetar dados de alta dimensão em um espaço de baixa dimensão de modo que os dados sejam remodelados para maximizar a separação das classes, maximizando a distância entre classes enquanto minimiza a distância dentro da classe (Xu et al., 2009; Park e Park, 2007; Liland, 2011). A análise discriminante quadrática (QDA) é uma técnica discriminante onde cada grupo é modelado por uma densidade normal separada e uma probabilidade prévia, sendo que a classificação de novas

observações é feita escolhendo-se o grupo que tem a maior probabilidade posterior. A classificação com funções quadráticas em mais de duas dimensões pode levar a resultados estranhos, principalmente quando os dados não são essencialmente multivariados normais (Johnson e Wichern, 2007; Liland, 2011).

Em muitos casos, a variável dependente compreende dois grupos de classificação (Macho/Fêmea, Sim/Não ou Alto/Baixo), sendo utilizada a denominação de análise discriminante em dois grupos. Em outras situações, a variável dependente compreende mais de dois grupos (por exemplo, as classificações Alto/Médio/Baixo ou Regular/Bom/Ótimo), onde aplica-se a denominação análise discriminante múltipla (MDA – *Multiple Discriminant Analysis*) (Hair et al., 2009).

Hair et al. (2009) sugerem um processo de seis etapas para aplicação da análise discriminante, sendo elas: (i) definição dos objetivos; (ii) abordagem das questões específicas de projeto e garantia de atendimento dos pressupostos subjacentes; (iii) derivação da função discriminante e determinação da significância estatística para divisão em dois ou mais grupos; (iv) desenvolvimento da matriz de classificação para avaliar a precisão dos resultados; (v) interpretação da função determinante para determinar quais variáveis independentes contribuem mais para a separação dos grupos; e (vi) validação da função discriminante com as amostras disponíveis.

Com relação aos objetivos, a análise discriminante pode ser aplicada aos casos onde deseja-se: (i) determinar a existência de diferenças estatisticamente significativas entre os perfis de pontuação média em um conjunto de variáveis para dois ou mais grupos predefinidos; (ii) determinar quais variáveis independentes contribuem mais para as diferenças entre os perfis de pontuação média para os dois ou mais grupos; (iii) estabelecer o número e composição das dimensões de discriminação entre grupos formados a partir do conjunto de variáveis independentes, e; (iv) para estabelecer procedimentos para classificação de objetos em grupos com base em suas pontuações em um conjunto de variáveis independentes (Hair et al., 2009).

Quanto à abordagem das questões específicas de projeto e garantia de atendimento dos pressupostos subjacentes, Hair et al. (2009) afirmam que o pesquisador deve centrar a sua atenção na definição das variáveis dependentes para garantir que os grupos formados por estas variáveis sejam exclusivos (de forma que cada observação possa ser classificada em apenas um dos grupos), e, em seguida, definir quais variáveis independentes devem ser incluídas na análise com base em pesquisas prévias similares ou na sua intuição. A quantidade de amostras deve ser definida de forma que a precisão da previsão atenda aos requisitos de pesquisa. A validação da

função discriminante pode ser obtida pela divisão da amostra em dois subgrupos, onde um será utilizado para determinação da função discriminante (amostra de análise) e o outro para validação da função discriminante (amostra de teste).

A derivação da função discriminante envolve as premissas relativas ao processo estatístico de previsão e classificação, e as premissas relativas a questões que afetam a interpretação dos resultados (relacionamento linear entre as variáveis, a normalidade multivariada dos dados e as estruturas desconhecidas de dispersão e covariância para os grupos definidos pelas variáveis dependentes). Caso estas premissas não sejam atendidas pelo conjunto de dados, o pesquisador deve optar por outros métodos de previsão ou classificação (Hair et al., 2009; Mário, 2002).

Quanto ao desenvolvimento da matriz de classificação e avaliação da precisão dos resultados, a importância das variáveis independentes para o modelo é calculada a partir da função discriminante. A pontuação  $Z$  discriminante é calculada para cada objeto na análise, e é utilizada em conjunto com a pontuação de corte para determinar a associação prevista ao grupo. O peso discriminante é o peso cujo tamanho se relaciona com o poder discriminatório das variáveis independentes entre os grupos de variáveis dependentes. A pontuação de corte é um critério contra o qual a pontuação  $Z$  discriminante de cada indivíduo é comparada para determinar a associação prevista do grupo. Em análises envolvendo dois grupos, a predição do grupo é calculada com base em uma única pontuação de corte (objetos com pontuação  $Z$  discriminante inferior à pontuação de corte são atribuídos a um grupo, enquanto objetos com pontuação superior à pontuação de corte são atribuídos ao outro grupo). Em análises envolvendo três ou mais grupos devem ser utilizadas funções discriminantes múltiplas, com diferentes pontuações de corte para cada função. A função discriminante é apresentada na forma da equação (16), onde  $Z_{jk}$  é a pontuação  $Z$  discriminante,  $\alpha$  é o ponto de intercepção,  $w_i$  é o peso discriminante para a variável independente  $i$ , e  $x_{ik}$  é a variável independente  $i$  para o objeto  $k$  (Hair et al., 2009; Guimarães e Moreira, 2008; Mário, 2002).

$$Z_{jk} = \alpha + w_1x_{1k} + w_2x_{2k} + \dots + w_nx_{nk} \quad (16)$$

Após o cálculo da pontuação  $Z$  discriminante, deve-se determinar a magnitude das diferenças entre os membros de cada grupo em termos de pontuação  $Z$  discriminante (comparação dos centroides dos grupos) para a avaliação da precisão dos resultados. Esta medida é importante para desenvolver as matrizes de classificação através do cálculo da pontuação de corte (*cutting score*, também conhecido como *critical Z value*). A pontuação de corte ótima  $Z_{CS}$  (entre os grupos A e B de tamanhos diferentes) ou  $Z_{CE}$  (entre os grupos A e B de tamanhos iguais) é

computada conforme as equações (17) e (18), onde  $N_A$  é o número de observações no grupo A,  $N_B$  o número de observações no grupo B,  $Z_A$  é o centroide do grupo A e  $Z_B$  é o centroide do grupo B (Hair et al., 2009; Guimarães e Moreira, 2008).

$$Z_{CS} = \frac{N_A Z_B + N_B Z_A}{N_A + N_B} \quad (17)$$

$$Z_{CE} = \frac{Z_A + Z_B}{2} \quad (18)$$

A classificação em grupos também pode ser obtida através da função discriminante linear de Fisher (FDA – *Fischer Discriminant Analysis*), a qual busca uma combinação linear de variáveis que melhor expliquem os dados (Hair et al., 2009). A separação entre as classes é definida pelo valor do Critério de Fisher, que é a razão entre a matriz de dispersão entre as classes  $S_b$  e a matriz de dispersão intraclasses  $S_w$ , cujos valores são calculados através das equações (19), (20) e (21), onde  $x_{ki}$  é a observação  $i$  em um espaço  $p$ -dimensional da classe  $k$ ,  $n_k$  é o número de amostras do subgrupo de amostra de teste da classe  $k$ ,  $\bar{x}_k$  representa o vetor médio da amostra  $k$  e  $\bar{x}$  representa a média geral (Mazzillo Júnior e Anzanello, 2013; Sugiyama, 2007, Sugiyama, 2006, Ye, 2007, Park e Park, 2007).

$$\text{Critério de Fisher} = \max \frac{|S_b|}{|S_w|} \quad (19)$$

$$S_b = \sum_{k=1}^K \sum_{i=1}^{n_k} n_k (\bar{x}_{ki} - \bar{x}_k) - (\bar{x}_{ki} - \bar{x}_k)^T \quad (20)$$

$$S_w = \sum_{k=1}^K n_k (\bar{x}_k - \bar{x})(\bar{x}_k - \bar{x})^T \quad (21)$$

A análise discriminante de Fisher (FLDA – *Fischer Linear Discriminant Analysis*) é uma técnica tradicional para classificações de classe binária, a qual procura uma direção que separe bem as médias das classes ao mesmo tempo em que obtém uma variação pequena torno destas médias, buscando a redução da dimensionalidade supervisionada de forma que a dispersão entre classes seja maximizada e a dispersão dentro da classe seja minimizada (Sugiyama, 2007; Sugiyama, 2006; Ye, 2007). Para Sugiyama (2007) e Park e Park (2007), há situações onde a FLDA não é adequada, entre elas, em problemas com poucas amostras onde o número de itens de dados é menor do que a dimensão dos dados (por exemplo, em problemas de classificação de texto e reconhecimento de face), e nas situações onde as amostras de uma classe formam vários clusters separados (por exemplo, no diagnóstico de doenças e no reconhecimento de dígitos manuscritos). Estas situações suscitaram o desenvolvimento de técnicas alternativas como a LDA Regularizada (RLDA), a LDA baseada na decomposição de valor singular generalizado (*LDA based on GSVD - Generalized Singular Value Decomposition*), entre outras.

A classificação dos objetos nos grupos depende do método de classificação utilizado. Ao utilizar a pontuação  $Z$  discriminante  $Z_{jk}$  e a pontuação de corte, deve-se classificar um objeto no grupo A quando  $Z_n < Z_{CT}$ , ou no grupo B quando  $Z_n > Z_{CT}$ , sendo  $Z_n$  a pontuação discriminante  $Z$  para determinado indivíduo  $n$ , e  $Z_{CT}$  é a pontuação de corte ótima. Ao utilizar a função discriminante linear de Fisher, um objeto é classificado no grupo com a maior pontuação da função de classificação (Hair et al., 2009).

A literatura cita semelhanças entre a análise discriminante e outras ferramentas multivariadas. Hair et al. (2009) citam que problemas envolvendo uma variável dependente não métrica com dois grupos de classificação podem ser endereçados com a utilização da técnica de regressão logística. Tabachnick e Fidell (2007) e Hair et al. (2009) afirmam que a análise discriminante é semelhante, porém o inverso da MANOVA (*Multivariate Analysis of Variance*). Ye (2007) mostra que a FLDA possui fortes conexões com a regressão linear (com o rótulo da classe como a saída), o que implica em dizer que a análise discriminante linear para classificações de classes binárias pode ser formulada como um problema de mínimos quadrados.

O PLS pode ser usado com uma resposta discreta para formar a análise discriminante PLS (PLS-DA), na qual a maximização é feita na matriz de covariância estimada entre grupos, ponderada pelo tamanho dos grupos ou por pesos personalizados. O PLS-DA é muitas vezes combinado com a LDA ou com a QDA para classificação de respostas discretas. Existem ainda outras versões da PLS, como a versões multiresposta (contínua) chamada PLS2, versões que podem usar respostas contínuas e discretas simultaneamente (chamadas de PLS canônico - CPLS), versões que separam as variações ortogonais de resposta no componente X (chamadas de PLS ortogonais - OPLS e OPLS-DA), e versões generalizadas do PLS para dados multivias (NPLS-DA - *N-way Partial Least Square Discriminant Analysis*). Existem ainda métodos focados em variáveis explanatórias altamente correlacionadas à resposta ou com elevados desvios padrão, geralmente resultando em modelos que demandam poucos componentes e interpretações mais simples, como os métodos PPLS, PPLS-DA e CPPLS (Liland, 2011; Hendriks et al., 2011).

### 2.3. SELEÇÃO DE VARIÁVEIS

Em muitas situações, um modelo razoável e estatisticamente válido pode ser obtido utilizando todas as variáveis de determinado conjunto de dados. Em grandes conjuntos de dados, porém, é comum observar-se muitas variáveis irrelevantes, ruidosas ou não confiáveis, fazendo-se necessária a remoção destas variáveis para melhorar as previsões, reduzir a complexidade do modelo (maior facilidade na visualização e compreensão dos dados e dos processos), melhorar as propriedades estatísticas do modelo, reduzir os requisitos de medição e armazenamento,



reduzir os tempos de formatação e utilização dos dados e definir preditores mais rápidos e rentáveis (Guyon e Elisseeff, 2003; Andersen e Bro, 2010; Balcaen e Oogheb, 2006). A redução do número de variáveis (através da remoção de variáveis irrelevantes e redundantes), reduzindo a dimensão de tal forma que os aspectos mais significativos dos dados sejam representados em um subconjunto de dados úteis a partir do conjunto de dados de entrada, é o objetivo dos métodos de seleção de variáveis (Tabakhi et al., 2014; Blum e Langley, 1997; Dash e Liu, 2003, apud Devijver e Kittler, 1982).

O conceito de relevância para seleção de variáveis foi explorado por Guyon e Elisseeff (2003), principalmente no tocante à seleção de variáveis úteis para construção de bons modelos de predição/classificação. Segundo estes autores, a seleção de variáveis para construção de bons preditores com base em sua relevância é geralmente inadequada em conjuntos de dados que contenham variáveis redundantes, visto que um subconjunto de variáveis úteis pode excluir muitas variáveis redundantes, porém relevantes para a análise. O conceito de relevância utilizado para seleção de variáveis na aprendizagem automática é detalhadamente discutido por Blum e Langley (1997), que apresentam cinco diferentes definições para relevância: (i) relevante para o objetivo; (ii) fortemente relevante para a amostra/distribuição; (iii) ligeiramente relevante para a amostra/distribuição; (iv) relevante como medida de complexidade, e; (v) utilidade incremental.

Os métodos de seleção de variáveis tornaram-se objeto de pesquisa em diversas áreas de aplicação e mineração de dados nas quais conjuntos de dados com de grande quantidade de variáveis estão disponíveis para análise. Os recentes avanços da tecnologia aumentam a facilidade e reduzem o custo de medição de múltiplas variáveis por objeto, tornando a seleção de variáveis cada vez mais importante para a redução e interpretação de dados. A manipulação dos dados em massa passou a ser um desafio para os pesquisadores, visto que dados são acumulados através de várias técnicas de aquisição, gerando um grande volume de dados brutos, dificultando e reduzindo a acurácia da análise (Guyon e Elisseeff, 2003; Liu e Yu, 2005; Mehmood et al., 2012; Stein et al., 2014; Cervo e Anzanello, 2015; Gnana et al., 2016).

Para Dash e Liu (2003), seleção de variáveis é uma técnica eficaz para classificação de dados e redução de dimensionalidade, podendo ser usada para encontrar um subconjunto ótimo de características relevantes no qual a precisão global de classificação é aumentada enquanto a dimensão dos dados é reduzida. Segundo Gnana et al. (2016), seleção de variáveis é um processo de remoção das características irrelevantes e redundantes de um conjunto de dados, a fim de melhorar o desempenho dos algoritmos de aprendizagem automática em termos de

precisão e tempo para construção do modelo. Para Brosfoske et al. (2014) modelos de seleção de variáveis incluem variáveis independentes que estão estatisticamente relacionadas com a resposta e descartam aquelas que são irrelevantes ou redundantes.

As técnicas de seleção de variáveis contrastam com outras técnicas de redução de dimensionalidade, como as baseadas em projeção (por exemplo, a PCA) ou em compressão (por exemplo, a Teoria da Informação), visto que estas não alteram a representação original das variáveis, mas apenas selecionam um subconjunto delas, preservando a semântica original das variáveis e permitindo a interpretação dos dados por um especialista da área (Saeys et al., 2007).

A vasta literatura sobre seleção de variáveis apresenta a sua utilização nas mais diversas aplicações, incluindo reconhecimento de padrões estatísticos, desenvolvimento de máquinas de aprendizagem, mineração de dados, análise de dados coletados em processos industriais, agrupamento de bateladas de produção com perfis semelhantes, previsão de falhas de negócios em finanças corporativas, processos logísticos e bioinformática (Yu e Liu, 2004; Balcaen e Oogheb, 2006; Saeys et al., 2007; Anzanello et al., 2009; Masiero e Anzanello, 2011; Zimmer, 2012; Anzanello, 2013; Stein et al., 2014; Cervo e Anzanello, 2015).

Embora a identificação e seleção de variáveis pode ser realizada manualmente, de forma empírica (através do conhecimento de especialistas ou com base em sua popularidade na literatura ou sucesso preditivo em pesquisas anteriores), o processo através de abordagens exploratórias é difícil quando a quantidade de variáveis é grande e estas são altamente correlacionadas, limitando o modelo à amostra analisada, definindo modelos não adequados à generalização e criando modelos não diversificados e contra intuitivos, ao ponto de, ao final da seleção manual, não haver certeza de que a previsão é a melhor possível (Gauchi e Chagnon; 2001; Balcaen e Oogheb, 2006; Masiero e Anzanello, 2011). Já a seleção de variáveis através de algoritmos possui uma ampla gama de alternativas, desde os métodos mais simples, passando pelos métodos de ponderação de variáveis e estendendo-se aos métodos mais complexos, como os métodos indutivos para aprendizagem automática (Blum e Langley, 1997).

### **2.3.1. Seleção de variáveis em contexto de PLS**

Além de sua capacidade de previsão, os métodos PLS são muito apreciados pela sua capacidade de redução da quantidade de variáveis do modelo, especialmente em ambientes com grande quantidade de dados. A regressão PLS (PLSR) é uma técnica PLS para a redução da dimensão, usada para reduzir o número de variáveis explanatórias num problema de regressão, eliminar a multicolinearidade do conjunto de variáveis explanatórias e estimar o subconjunto de variáveis

explicativas ideais para prever as variáveis dependentes. Embora a regressão PLSR em sua forma original não tenha implementação direta para seleção de variáveis (o foco do método é encontrar o subespaço linear relevante das variáveis explicativas e não as próprias variáveis), a literatura apresenta um grande número de métodos para seleção de variáveis com base em PLSR (Ferrer, et al., 2008; Roy e Roy, 2008; Mateos-Aparicio, 2011; Mehmood et al. (2012).

Entre as abordagens estatísticas clássicas para seleção de variáveis destacam-se a *Forward Selection* (FS - escolha das variáveis que dão os melhores prognósticos, uma a uma, a partir da variável com menor erro de predição), a *Backward Selection* (BS – assemelha-se à seleção para a frente, porém usa o modelo completo a partir do qual as variáveis que contribuem menos para as previsões são removidos uma a uma), *Stepwise Multiple Regression* (SMR - combinação de FS e BS, começa selecionando variáveis como na FS, mas com a condição de que uma variável pode ser removida caso alguma variável adicionada posteriormente torne-a menos importante), *Simple Regression* (SR – começa pela regressão simples para cada uma das variáveis explicativas, mantendo apenas as variáveis que obedecem a determinados limites), *Best Subset Selection* (BSS - analisa modelos de regressão linear múltipla em todas as combinações de variáveis e escolhe a combinação que confere o melhor ajuste ao modelo) (Andersen e Bro, 2010; Gauchi e Chagnon, 2001, Chong e Jun, 2005).

O método BSS analisa os modelos de regressão linear múltipla em todas as combinações de variáveis de forma exaustiva e escolhe a combinação que oferece o melhor ajuste, porém, só é possível quando há poucas variáveis e em tamanhos de amostras adequados para evitar superposição (tamanhos de amostra menores não podem suportar o grande número de graus de liberdade muitas vezes necessário). O método BSS encontra para cada  $k \in \{0, 1, 2, \dots, p\}$  o subconjunto de tamanho  $k$  que dá a menor soma residual de quadrados. A escolha de  $k$  envolve a compensação entre viés e variância (observando o princípio da parcimônia), sendo que, normalmente, escolhe-se o menor modelo que minimiza a estimativa do erro de previsão esperada (Andersen e Bro, 2010; Friedman et al., 2001).

A seleção de variáveis a partir de FS, BS, SMR ou BSS resulta na criação de diferentes modelos contendo um determinado subconjunto de variáveis independentes, e o pesquisador precisa determinar qual desses modelos é o melhor. Como regra, o modelo contendo todos os preditores terá sempre o menor RSS e o maior  $R^2$ , porém, estes indicadores não são adequados para escolha do modelo com menor erro de predição entre modelos com diferentes números de preditores. Entre as técnicas adequadas para selecionar o melhor modelo com relação ao erro de teste estão o  $R^2$  ajustado, Cp (critério Cp de Mallow), AIC (*Akaike Information Criterion*), BIC (*Bayesian*

*Information Criterion*), BCOR (*Backward Correlations*), RCOR (*Random Correlations*), RCOEF (*Random Coefficients*), entre outros (Gauchi e Chagnon (2001; James et al., 2013; Johnson e Wichern, 2007; Denham, 2000).

O  $C_p$  de Mallows foi criado por Colin Mallows com o intuito de facilitar a comparação entre vários subconjuntos de variáveis de forma a medir a qualidade da predição do modelo, e é dado pela equação (22), onde  $SSE_p$  é a soma dos quadrados dos erros para modelo com  $p$  parâmetros (incluindo a intersecção, se houver), o  $MSE_m$  é a média dos desvios quadráticos dos erros (para o modelo com todos os  $m$  preditores),  $p$  é o número de preditores e  $n$  é o número de observações da amostra (Mallows, 1973; Floriano et al., 2006; Oliveira, 2010; Boisbunon et al., 2013; Farenhorst et al., 2008).

$$C_p = \frac{SSE_p}{MSE_m} - (n - 2p) \quad (22)$$

O  $C_p$  de Mallows apoia-se no pressuposto de que, se para um subconjunto  $I$  de variáveis explicativas o erro de predição esperado for baixo, então essas variáveis serão relevantes para prever  $Y$ : Na prática, a regra para selecionar o melhor conjunto de variáveis é a minimização de  $C_p$ , porém, Mallows alerta que esta regra não deve ser aplicada em todos os casos, especialmente quando o modelo contém variáveis explicativas altamente correlacionadas (Boisbunon et al., 2013). Um valor de  $C_p$  baixo indica que o modelo é relativamente preciso, possuindo variância pequena para a estimativa dos coeficientes da regressão e para a previsão de respostas futuras. A estatística  $C_p$  de Mallows indica a quantidade de viés na estimativa dos coeficientes de regressão (se variáveis importantes são deixadas de fora de uma previsão, o viés estará presente nos coeficientes de regressão). Como a estatística  $C_p$  é delineada contra o número de parâmetros  $p$ , quanto mais próximo  $C_p$  for de  $p$  menos tendenciosas são as estimativas dos parâmetros e melhor é o modelo (em estimativas sem viés, o  $C_p$  é igual ao número de preditores). Modelos com baixa capacidade preditiva e tendência têm valor de  $C_p$  maior do que  $p$  (Veenstra et al., 2008; Oliveira, 2010; Teixeira et al., 2013).

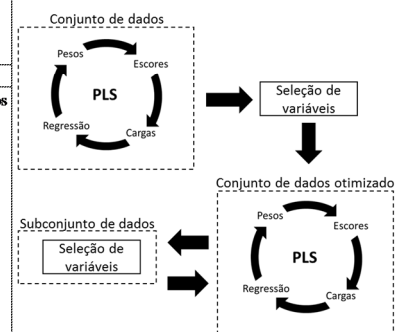


Höskuldsson (2001) apresenta em seu trabalho dois métodos de seleção de variáveis para regressões PLS. O primeiro método procura por intervalos de variáveis (ao invés de variáveis individuais, para obter os maiores vetores de pontuação possível) que mostram alta correlação com a variável dependente, visto que, ao trabalhar com intervalos, obtêm-se regressões PLS mais estáveis do que utilizando apenas algumas variáveis selecionadas (dado que os vetores de pontuação com base em intervalos são maiores que os baseados em variáveis). Uma das maneiras de encontrar intervalos úteis obedece aos seguintes passos: (i) encontrar a variável

com a maior correlação com a variável dependente; (ii) encontrar um intervalo em torno desta variável para usar na regressão; (iii) realizar a regressão PLS com base no intervalo; (iv) ajustar as variáveis independentes aos resultados obtidos neste intervalo; e (v) reiniciar os passos para definir uma nova variável inicial. Este método é tido como eficiente quando se observam poucos (e relativamente grandes) intervalos de variáveis no conjunto de dados. O segundo método é indicado para situações envolvendo uma grande quantidade de pequenos intervalos com correlações ou covariâncias pequenas e seus passos são: (i) optar por uma medida de correlação ou covariância que deve ser usada; (ii) encontrar a variável que tem o valor numérico mais alto; (iii) dividir o intervalo de zero para o valor numericamente mais alto em  $n$  intervalos (quantidade a ser definida pelo pesquisador); (iv) encontrar os intervalos de variáveis que mostram valores acima dos limites encontrados em (iii); e (v) realizar as  $n$  regressões PLS.

Zimmer e Anzanello (2014) apresentam um método para seleção de variáveis de processo com propósito de predição. Índices de importância das variáveis de processo são gerados pela regressão PLS para identificação das variáveis mais relevantes, as quais são reduzidas através da abordagem *Backward Selection*, sendo o desempenho do modelo de regressão resultante após cada eliminação de variável avaliado por intermédio do indicador RMSE (*Root Mean Square Error*). Anzanello (2009) propõe a integração da regressão PLS a ferramentas de classificação *Z-Nearest Neighbor* e *Support Vector Machine*, visando à seleção de variáveis para fins de categorização de bateladas de produção em duas classes.

A literatura apresenta diferentes classificações das técnicas de seleção de variáveis com base em PLSR. Os autores classificam as técnicas de seleção de variáveis em diferentes categorias ou métodos dependendo de como elas combinam a busca da seleção de variáveis com a construção do modelo de classificação, ou com base em como o algoritmo de aprendizado supervisionado é empregado no processo de seleção de variáveis. Os principais métodos são os de filtro (*filter*, por exemplo, coeficientes  $b$ , pesos  $w$ , VIP), métodos de envelope (*wrapper*, por exemplo, UVE-PLS, BVE-PLS, IPW-PSL, BQ), métodos incorporados (*embedded*, por exemplo, IVS, PPLS, SPLS) e os métodos híbridos (*hybrid*) (Blum e Langley, 1997; Liu e Yu, 2005; Saeys et al., 2007; Mehmood et al., 2012; Fassnacht et al., 2014; Loreto, 2014; Tabakhi et al., 2014; Gnana et al., 2016). O Quadro 3 apresenta as principais características de cada método, suas vantagens e desvantagens.

<b>FILTRO (FILTER)</b>	
<p>Métodos de filtro (filter) são simples e fornecem rapidamente um ranking das variáveis com relação a alguma medida de importância. Identificam as variáveis relevantes dentro de um conjunto de dados e selecionam as variáveis como um passo de pré-processamento, independentemente do preditor escolhido. Avaliam a relevância das variáveis olhando somente para as propriedades intrínsecas do conjunto de dados. Na maioria dos casos, a relevância das variáveis é calculada através de coeficientes de correlação e as variáveis de baixa relevância são removidas.</p>	
<b>Vantagens</b>	<b>Desvantagens</b>
<ul style="list-style-type: none"> <li>• Rápido;</li> <li>• Dimensionável;</li> <li>• Independente do classificador;</li> <li>• Modela a dependência dos recursos;</li> <li>• Menor complexidade computacional do que os métodos envelopados (wrapper);</li> <li>• Robusto contra sobre-ajuste.</li> </ul>	<ul style="list-style-type: none"> <li>• Ignora a dependência dos recursos;</li> <li>• Ignora a interação com o classificador;</li> <li>• Pode ter consideravelmente menos variância;</li> <li>• Pode levar à seleção de um subconjunto redundante de variáveis;</li> <li>• Propenso a sobre-ajuste.</li> </ul>
<b>ENVELOPE (WRAPPER)</b>	
<p>Método simples e eficaz de seleção de variáveis que utiliza o método de filtro (filter) de forma iterativa, identificando as variáveis que serão re-introduzidas no modelo de seleção de variáveis como um subconjunto de dados, ocorrendo o "envelopamento" dos dados para produzir modelos reduzidos. Os subconjuntos de dados são escolhidos de acordo com o seu poder preditivo. A utilidade relativa dos subconjuntos de dados é avaliada, realizando uma busca no conjunto de dados por possíveis subconjuntos de dados, e vários subconjuntos de dados são gerados e avaliados.</p>	
<b>Vantagens</b>	<b>Desvantagens</b>
<ul style="list-style-type: none"> <li>• Simples;</li> <li>• Interage com o classificador;</li> <li>• Modela a dependência dos recursos.</li> </ul>	<ul style="list-style-type: none"> <li>• Risco de sobre-ajuste;</li> <li>• Propenso a ficar preso em locais ótimos (greedy search);</li> <li>• Seleções dependentes do classificador;</li> <li>• Computacionalmente intensivo (risco de NP-hard).</li> </ul>
<b>INCORPORADO (EMBEDDED)</b>	
<p>O método incorporado (embedded) orienta sua busca estimando mudanças no valor da função objetivo fazendo movimentos no espaço do subconjunto de dados. A busca de um subconjunto ótimo de recursos está embutida na construção do classificador, e pode ser visto como uma busca no espaço combinado de conjunto e subconjuntos de dados. Assim como nas abordagens envelopadas (wrapper), as abordagens incorporadas (embedded) são específicas para um determinado algoritmo de aprendizagem.</p>	
<b>Vantagens</b>	<b>Desvantagens</b>
<ul style="list-style-type: none"> <li>• Interage com o classificador;</li> <li>• Melhor complexidade computacional do que os métodos envelopados (wrapper);</li> <li>• Modela a dependência dos recursos;</li> <li>• Melhor utilização dos dados disponíveis do que os métodos envelopados (wrapper);</li> <li>• Attingem uma solução mais rápida do que os métodos envelopados (wrapper).</li> </ul>	<ul style="list-style-type: none"> <li>• Seleções dependentes do classificador.</li> </ul>
<b>HÍBRIDO (HYBRID)</b>	
<p>As abordagens híbridas (hybrid) selecionam as variáveis em duas fases: na primeira fase, elas reduzem o conjunto de dados original usando a abordagem de filtro (filter), e na segunda fase a abordagem de envelope (wrapper) é aplicada para selecionar o melhor subconjunto de variáveis no conjunto de dados reduzido.</p>	
<b>Vantagens</b>	<b>Desvantagens</b>
<ul style="list-style-type: none"> <li>• Combina as vantagens dos métodos filtro (filter) e envelope (wrapper);</li> <li>• Reduz a complexidade computacional;</li> <li>• Aplicação mais restrita em comparação com os métodos de filtragem, uma vez que usam o algoritmo de aprendizado supervisionado no processo de seleção de recurso;</li> <li>• Menor risco de eliminar variáveis relevantes do que na abordagem filtro (filter);</li> <li>• Melhor processamento de conjunto de dados de grande porte do que os métodos de envelope (wrapper).</li> </ul>	<ul style="list-style-type: none"> <li>• Demandam mais tempo computacional do que os métodos de filtro (filter).</li> </ul>



Quadro 3: Técnicas de seleção de variáveis

Fonte: Adaptado de Saeys et al. (2007), Guyon e Elisseeff (2003) Mehmood et al. (2012), e Tabakhi et al. (2014)

### 3. MÉTODO

Neste capítulo são descritas as etapas operacionais da abordagem para seleção de variáveis preditivas no contexto de redução do risco de obsolescência ou deterioração do inventário em empresas fabricantes de bens de consumo que forneçam para grandes redes varejistas.

A abordagem proposta envolve a investigação dos fatores que contribuem para obsolescência do inventário, a classificação de inventários de produtos acabados em faixas de idade através da análise discriminante, a seleção de variáveis independentes em modelos de regressão preditivos, a projeção deste inventário ao longo do tempo a partir de um conjunto recomendado de variáveis e a definição de ações para reduzir o risco de obsolescência futuro.

O método proposto contempla cinco etapas, as quais serão explicadas detalhadamente no decorrer deste capítulo, conforme exposto na Figura 1.

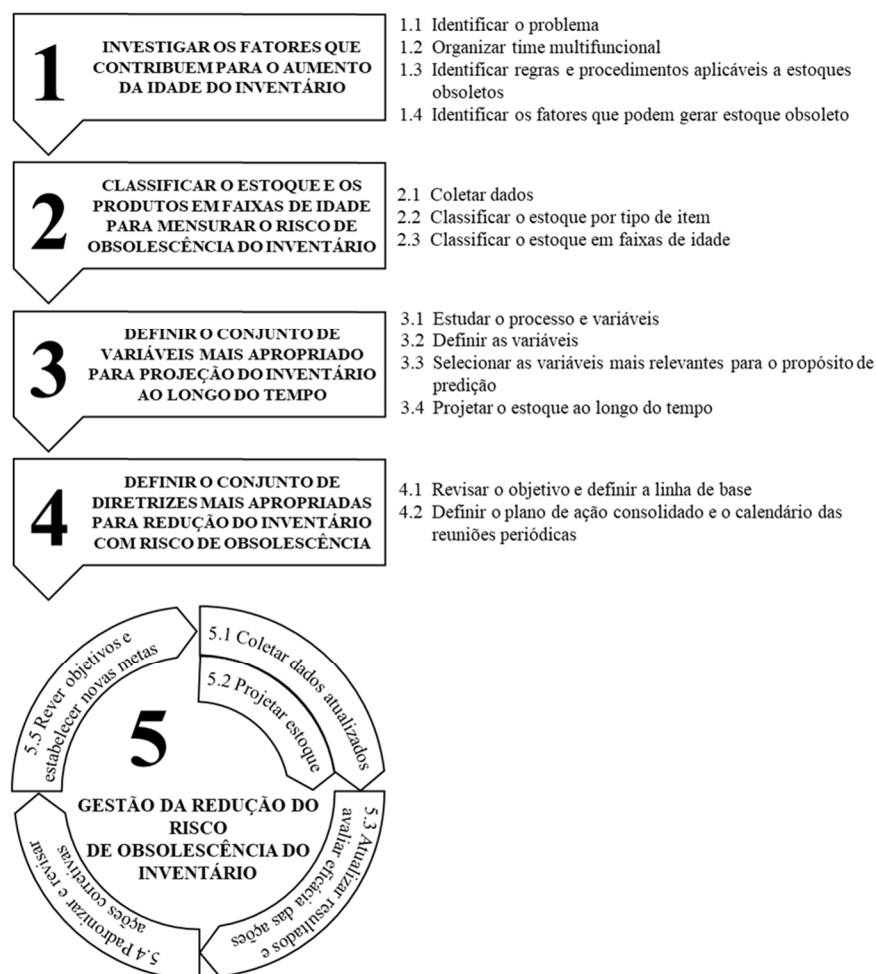


Figura 1: Etapas do modelo proposto  
Fonte: Elaborado pelo Autor

As primeiras quatro etapas do método compreendem a coleta e análise dos dados e do ambiente, a classificação do estoque, a criação de um cenário futuro com base na projeção do estoque ao longo do tempo e a proposição de ações corretivas para reduzir o risco de obsolescência futuro. Tais etapas foram realizadas uma única vez no início do projeto, sendo preparatórias e fundamentais para que a melhoria contínua do processo seja perseguida através da etapa 5. A etapa 5, por sua vez, foi realizada mensalmente de forma sistêmica, em um ciclo contínuo similar ao Ciclo PDCA.

### 3.1. INVESTIGAR OS FATORES QUE CONTRIBUEM PARA O AUMENTO DA IDADE DO INVENTÁRIO

A primeira etapa do método proposto consiste na investigação dos fatores que contribuem para o aumento da idade do inventário. Esta etapa é fundamental para fundamentação do processo e consiste na (i) identificação do problema; (ii) organização do time multifuncional; (iii) identificação das regras e procedimentos aplicáveis a estoques obsoletos ou deteriorados; e (iv) identificação dos fatores que podem gerar estoques obsoletos ou deteriorados.

#### 3.1.1. Identificar o problema

A identificação do problema é necessária sempre que se depara com um efeito indesejado como resultado de um processo. O treinamento para uma investigação começa com a definição do problema sob estudo e o desenvolvimento do projeto de estudo de caso. A correta identificação do problema é fundamental para a precisão das coletas de dados e das ações definidas para sua solução, o que justifica um investimento de tempo e recursos adequados por parte das empresas para que este possa ser bem identificado e definido. Sendo assim, é altamente recomendado que o problema a ser endereçado esteja alinhado com os objetivos estratégicos da organização (Campos, 2009; Yin, 2015; Antony, 2006).

A alta complexidade dos sistemas empresariais – em especial dos sistemas de gestão de demanda e controle de inventários, os quais envolvem uma grande quantidade de variáveis que afetam, direta ou indiretamente, o resultado financeiro das empresas – reforçam a necessidade da correta identificação e descrição do problema de obsolescência do inventário, de forma detalhada e delimitada.

#### 3.1.2. Organizar time multifuncional

Um time multifuncional deve ser formado por um pequeno número de pessoas com habilidades complementares, comprometidas com um mesmo propósito, metas de desempenho e abordagem, com o objetivo de proporcionar sinergia e maximizar os resultados de forma que o



todo seja maior do que a soma das partes. Os times multifuncionais devem agregar pessoas de diferentes formações, diretamente afetadas pelo problema ou diretamente envolvidas na sua solução. Os autores recomendam que os times multifuncionais possuam de três a cinco participantes principais (não mais do que dez). Além da formação técnica e experiência profissional diversa, os times multifuncionais devem possuir um líder (ou analista principal), recursos operacionais (ou analistas associados) para operacionalizar as questões administrativas e realizar as tarefas burocráticas relacionadas, especialistas nos assuntos relacionados à análise, representantes de fornecedores (quando necessário), além de participantes com um perfil mais crítico, para forçar a equipe a enxergar outros pontos de vista e encontrar falhas na lógica através de perguntas persistentes (Latino et al., 2006).

### **3.1.3. Identificar regras e procedimentos aplicáveis a estoques obsoletos ou deteriorados**

Diferentes indústrias possuem diferentes normas, procedimentos e políticas aplicáveis a estoques obsoletos. Empresas que adotam o padrão de contabilidade internacional (IFRS), por exemplo, possuem exigências ao lançamento de provisões contábeis para obsolescência do estoque em função da idade do inventário (Silva et al., 2011; Cella et al., 2011; Thomaz et al., 2013; Souza e Coutinho Filho, 2007). Já a maioria das indústrias que produzem produtos perecíveis, além das questões regulatórias relativas, estão sujeitas a normas e políticas de seus clientes quanto à validade mínima dos produtos a serem faturados a estes clientes.

Identificar as normas, procedimentos, políticas, questões regulatórias ou exigências de clientes que impactem de alguma forma a obsolescência de seu inventário é fundamental para a identificação das variáveis e determinação do plano de ação. O conhecimento dos especialistas das áreas envolvidos no time multifuncional permite o levantamento destas questões, para o qual podem ser aplicadas diversas técnicas como entrevistas com especialistas das áreas, *brainstorming*, diagrama de causa e efeito, método dos 5 porquês, mapeamento de processos, árvores de falha ou diagramas lógicos (Latino et al., 2006).

### **3.1.4. Identificar fatores que podem gerar estoque obsoleto ou deteriorado**

São inúmeros os fatores que influenciam o risco de obsolescência de determinado item, entre eles, o próprio valor do item, a sua taxa de obsolescência, a incerteza da demanda e da oferta, a diminuição da sua conveniência e/ou função, a incompatibilidade do ciclo de vida dos componentes de um produto acabado e o excesso de inventário, entre outros (Chopra e Sodhi, 2004; Butt et al., 2015; Tang e Musa, 2011; Kessler e Brendel, 2016).

Determinados fatores tendem a ocorrer com maior frequência em tipos de produtos e/ou negócios específicos, como, por exemplo, a incompatibilidade do ciclo de vida, mais frequente em bens de capital (devido ao longo ciclo de vida do produto final), ou a obsolescência psicológica, mais comum em bens de consumo (Kessler e Brendel, 2016; Kumar e Saranga, 2010). Desta forma, identificar os fatores de risco inerentes ao seu produto e/ou negócio é fundamental para redução do risco de obsolescência do inventário, o que pode ser obtido através do conhecimento dos especialistas das áreas envolvidos no time multifuncional, entrevistas com especialistas das áreas, *brainstorming*, diagrama de causa e efeito, método dos 5 porquês, mapeamento de processos, árvores de falha ou diagramas lógicos.

### 3.2. CLASSIFICAR O ESTOQUE EM FAIXAS DE IDADE PARA MENSURAR O RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO DO INVENTÁRIO

A segunda etapa do método proposto consiste na classificação do estoque de produtos em faixas de idade para mensurar o risco de obsolescência ou deterioração do inventário. Esta etapa consiste em (i) coletar dados; (ii) classificar o estoque por tipo de item, e; (iii) classificar o estoque em faixas de idade.

#### 3.2.1. Coletar dados

A chave para uma análise bem-sucedida é certificar-se de que a equipe dispõe dos dados e informações necessárias para determinação das causas subjacentes do problema em estudo (Latino et al., 2006). Para tal, o time multifuncional deve rever o problema e os fatores que podem gerar estoque obsoleto ou deteriorado e determinar quais dados e informações serão necessários para determinar as causas raiz. Ferramentas como *brainstorming*, diagrama de causa e efeito, método dos 5 porquês e mapeamento de processos, bem como análises prévias de causa raiz ou análise de problemas similares tratados anteriormente pela empresa podem contribuir para definição das variáveis a serem coletadas.

A coleta de dados, porém, deve ser precedida de um estudo inicial sobre o problema pelo pesquisador e sua equipe, e deve prever procedimentos explícitos e previamente planejados, de forma a abordar todas as perspectivas do processo (Yin, 2015). Além disso, cada dado deve ter um responsável pela sua obtenção ou coleta definido de forma clara e formal, o qual conhecerá e observará os procedimentos previamente definidos para sua obtenção.

#### 3.2.2. Classificar o estoque por tipo de item

A classificação dos itens em diferentes categorias é necessária para que se possa aplicar os métodos mais adequados de gestão para cada categoria (Boylan et al., 2008; Syntetos et al., 2010; Wu, 2013).

A classificação do inventário por tipo de item pode ser realizada tanto de forma empírica quanto de forma investigativa, em função da forma como os dados estão disponíveis, da existência de uma classificação prévia dos itens e do objetivo do projeto. De forma empírica, o inventário pode ser classificado com base nos parâmetros do cadastro de itens do sistema ERP (*Enterprise Resource Planning*) das empresas onde o método for aplicado (por exemplo, componentes, produtos acabados, peças de reposição, famílias de produtos, etc.) ou no conhecimento dos especialistas das áreas de produtos e gestão de estoques da empresa.

Em situações onde esta informação não estiver disponível, for desconhecida ou, embora existente, na opinião do time multifuncional e especialistas da empresa não puder ser relacionada diretamente com a causa raiz do problema, a classificação pode ser realizada de forma investigativa, separando os conjuntos distintos de objetos ou observações em grupos previamente definidos e classificando uma nova observação em um dos grupos previamente estabelecidos através da utilização da análise discriminante (Hair et al., 2009; Johnson e Wichern, 2007; Mário, 2002; Tabachnick e Fidell, 2007). A definição prévia dos grupos, neste caso, deve ser realizada pelo time multifuncional. Os grupos devem ser definidos em consonância com o problema e com os fatores que podem gerar estoque obsoleto ou deteriorado, para que posteriormente possam ser aplicados os métodos mais adequados de gestão para o conjunto de itens classificados dentro de cada grupo.

Nos estudos de caso conduzidos pelo autor, foram realizadas classificações de forma empírica em situações onde havia uma classificação prévia dos itens que atendia aos objetivos do projeto (Estudo de Caso 1), e através da utilização da análise discriminante em situações onde não havia classificação prévia dos itens ou que a classificação existente não estivesse diretamente relacionada com a causa raiz do problema (Estudo de Caso 2).

### **3.2.3. Classificar o estoque em faixas de idade**

Apesar da escassa literatura acadêmica abordando o envelhecimento do inventário sob a ótica do risco de obsolescência (Wu, 2013; Chen et al., 2011; Li et al., 2014; Westerman, 2015; Raza et al., 2017), os estudos de caso realizados pelo autor obtiveram êxito na classificação do inventário em faixas de idade, com posterior determinação de medidas precisas para redução do risco de obsolescência do inventário específicas para cada faixa de idade. Além disso, o

padrão de contabilidade internacional IFRS, utilizado em uma das empresas objeto do estudo de caso, recomenda o lançamento de provisões contábeis para obsolescência do estoque em função da idade do inventário (Silva et al., 2011; Cella et al., 2011; Thomaz et al., 2013; Souza e Coutinho Filho, 2007).

A classificação dos produtos em faixas de idade depende unicamente da data de fabricação de determinado item, não demandando, portanto, a definição de outros critérios de classificação por parte do pesquisador. Porém, da mesma forma que a classificação por tipo de item, a classificação em faixas de idade pode ser realizada tanto de forma empírica quanto de forma investigativa, em função da forma como os dados estão disponíveis nos registros da empresa.

Para produtos acabados, nos sistemas de planejamento e controle de produção da indústria em geral há a figura da ordem de produção que, quando finalizada, transforma as matérias primas, insumos e demais recursos aplicados na fabricação em um produto acabado. Os sistemas registram a data de finalização (ou apontamento) da ordem de produção em seus bancos de dados para efeitos de controle de estoque e de custo médio, requisitos contábeis. Algumas indústrias fabricantes de bens de consumo possuem ainda sistemas para controle do número de série dos produtos produzidos (para efeito de garantia legal) ou de lote (para efeitos de data de validade, quando perecíveis), nos quais a data de fabricação dos produtos acabados também pode ser obtida.

Para matérias primas, os sistemas de controle de estoque registram em seus bancos de dados as datas de entrada das matérias primas no estoque e as datas em que as mesmas foram movimentadas (transferidas de local de estoque, consumidas por ordens de produção ou alteradas por outras movimentações contábeis), também para efeitos de controle de estoque e de custo médio, requisitos contábeis.

A forma como as datas de produção dos produtos acabados ou de entrada das matérias primas serão retiradas do sistema para efeito de controle da idade do inventário dependerá de como o banco de dados está estruturado, demandando uma solução específica para cada caso, que deve ser obtida em conjunto com a área de Tecnologia da Informação (TI) ou com o suporte técnico especializado (por exemplo, fornecedor do software de gestão ou ERP).

Após a obtenção da data de fabricação dos produtos acabados e da data de recebimento das matérias primas, deve-se classificar os itens em faixas de idade, para que se possa aplicar os métodos mais adequados de gestão para o conjunto de itens em cada faixa de idade. A extensão da faixa de idade deve ser definida pelo time multifuncional em consonância com o problema

e com os fatores que podem gerar estoque obsoleto ou deteriorado, de forma a que as ações definidas para cada faixa de idade contribuam para redução do risco de obsolescência ou deterioração do estoque.

Nos estudos de caso conduzidos pelo autor, a classificação do inventário no Estudo de Caso 1 foi realizada de forma empírica (através de um novo relatório criado no sistema ERP), enquanto no Estudo de Caso 2, por exigência da ANVISA (rastreadabilidade dos produtos por lotes de produção), o inventário de produtos acabados e matérias primas já se encontrava devidamente classificado em faixas de idade no sistema ERP da empresa.

As faixas de idade em que o inventário será dividido também devem ser definidas pelo time multifuncional, em função das características de cada empresa onde o método será implantado, de forma que se possa aplicar os métodos mais adequados de gestão para cada faixa de idade com vistas a redução do risco de obsolescência ou deterioração, respeitando a dinâmica de cada negócio. Em ambos os estudos de caso apresentados neste trabalho, os itens foram classificados em faixas de seis meses, intervalo considerado apropriado pelos times multifuncionais das duas empresas. No Estudo de Caso 1, devido à natureza dos produtos (bens de consumo duráveis, com vida útil superior a 5 anos e renovação das linhas de produtos em ciclos de aproximadamente dezoito meses por exigência do mercado consumidor ou por inovações tecnológicas) e exigências contábeis (provisão para obsolescência do inventário com idade acima de 180 dias) optou-se por monitorar o envelhecimento do inventário acima de 180 dias apenas, separando a partir daí o inventário em faixas consecutivas de 180 dias até o limite de três anos (a partir deste limite, todo o inventário acima de três anos pertence ao mesmo grupo). Já no Estudo de Caso 2 (bens de consumo não duráveis, com validade máxima de dois anos), optou-se por monitorar os itens com validade inferior a 2 anos em faixas de 6 meses.

Dependendo da natureza do produto da empresa e, principalmente, para que se possa aplicar os métodos mais adequados de gestão para cada faixa com vistas a redução do risco de obsolescência ou deterioração, faixas de idade com períodos diferentes (maiores ou menores) podem ser necessárias para melhor explicar o envelhecimento do inventário.

### 3.3. DEFINIR O CONJUNTO DE VARIÁVEIS MAIS APROPRIADO PARA PROJEÇÃO DO INVENTÁRIO AO LONGO DO TEMPO

A terceira etapa do método proposto consiste na definição do conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo. Esta etapa consiste em (i) estudar o

processo e variáveis; (ii) definir as variáveis; (iii) reduzir o número de variáveis; e (iv) projetar o estoque ao longo do tempo.

### **3.3.1. Estudar o processo e variáveis**

O estudo prévio do processo e a definição das características relacionadas ao objetivo da análise são etapas importantes para o processo de planejamento e coleta de dados, de forma a estabelecer quais questões devem ser estudadas, quais são as variáveis relevantes do processo, quais dados devem ser coletados e como os resultados serão analisados. Em resumo, é essencial que o time multifuncional, com base no problema, nos fatores que podem gerar estoque obsoleto ou deteriorado e na coleta de dados, desenvolva uma teoria que servirá de base para definição das variáveis a serem estudadas para projeção do inventário ao longo do tempo (Yin, 2015).

### **3.3.2. Definir as variáveis**

A coleta de dados isolados separa o fenômeno de seu contexto, tornando possível dedicar atenção especial àquelas variáveis julgadas de maior relevância pelos pesquisadores. Após a análise do processo e suas variáveis, os resultados da coleta de dados devem ser validados pelo time multifuncional e especialistas das áreas, bem como por funcionários que operam diretamente nas principais atividades do processo observado. A qualidade dos dados e a relevância das variáveis para o fenômeno em estudo é fundamental para garantir a eficácia das análises posteriores e a efetividade das ações delas decorrentes (Yin, 2015).

Com base na teoria que servirá de base para definição das variáveis a serem estudadas para projeção do inventário, o time multifuncional deve selecionar, de forma empírica, dentre todas as variáveis coletadas na coleta de dados, as variáveis que serão utilizadas para a próxima etapa do processo. Para auxiliar nesta seleção - dada a complexidade dos sistemas de gestão de estoques e planejamento industrial e do grande número de variáveis geralmente envolvidas nos processos de obsolescência ou deterioração de inventários - a teoria desenvolvida pelo time multifuncional pode ser testada com a utilização do  $R^2$ . Com o propósito de melhor entender a relação das variáveis com o problema investigado, pode-se aplicar, inicialmente, a regressão linear simples ou múltipla (dependendo do número de variáveis estudadas) ao conjunto de variáveis selecionadas, realizando diferentes análises alterando as variáveis utilizadas em cada uma das análises, até que o maior coeficiente  $R^2$  seja obtido. Diferentes combinações devem ser testadas pelo time multifuncional, com base na teoria desenvolvida, de forma a encontrar a combinação de variáveis para as próximas etapas do processo.

### **3.3.3. Selecionar as variáveis mais relevantes para o propósito de predição**

Um modelo estatisticamente válido pode ser obtido utilizando todas as variáveis de determinado conjunto de dados, porém, a redução do número de variáveis tipicamente conduz a um modelo de previsão mais rápido, com menor complexidade, com melhores propriedades estatísticas, e que demande menores requisitos de coleta de dados, processamento e armazenamento de informações. Tal objetivo é alcançado excluindo do modelo as variáveis irrelevantes, ruidosas ou não confiáveis (Guyon e Elisseeff, 2003; Andersen e Bro, 2010; Balcaen e Oogheb, 2006).

Os métodos PLS são muito apreciados pela sua capacidade de redução da quantidade de variáveis do modelo. A redução das variáveis para efeitos de projeção dos resultados é obtida através da regressão PLS com o método BSS, utilizando o  $R^2$  ajustado e o critério Cp de Mallow, com suporte do software Minitab. A abordagem *Best Subset Selection* analisa modelos de regressão linear múltipla em todas as combinações de variáveis e escolhe a combinação que confere o melhor ajuste ao modelo. O modelo contendo todos os preditores tipicamente apresentará o maior  $R^2$ , porém, não necessariamente o menor erro de predição. Para selecionar o melhor modelo com relação ao erro de teste foi utilizado o critério Cp de Mallow, buscando a redução das variáveis irrelevantes, ruidosas ou não confiáveis do modelo.

#### **3.3.4. Projetar o estoque ao longo do tempo**

Modelos de previsão são importantes para definir métodos de previsão de falhas, desenvolver sistemas de alerta precoces, gerar informações úteis para a tomada de decisões e melhorar os resultados dos negócios, entre eles, os métodos estatísticos de previsão de (Aziz e Dar, 2006; Ferrer et al., 2008; Huang et al., 2008; Boylan et al., 2008; Van Jaarsveld e Dekker, 2010; Syntetos et al., 2010; Wu, 2010; Bonney e Jaber, 2011; Huang et al., 2005; Jennings, 2015; Wu, 2013). Ao classificar o inventário por tipos de item e faixas de idade e projetar o risco de obsolescência do estoque, tornou-se possível: (i) definir ações específicas para cada grupo e/ou faixa de idade; (ii) analisar a tendência (crescimento, redução) de determinado grupo e/ou faixa de idade ao longo do tempo; (iii) acompanhar a efetividade das ações específicas ao longo do tempo para cada grupo e/ou faixa de idade; (iv) priorizar ações e/ou recursos para os grupos e/ou faixas de idade cujo risco de obsolescência traga o maior impacto ao resultado do negócio.

A projeção do estoque ao longo do tempo foi realizada através da regressão PLS com suporte do software Minitab. Para tal, foram utilizadas as variáveis mais relevantes para o propósito de predição e o conjunto original de dados coletados. O resultado da projeção (variável dependente Y, que indica o envelhecimento do inventário a cada período) representa o risco de obsolescência ou deterioração futuro a cada período.

A equação de regressão fornecida pelo software Minitab foi utilizada para projetar o envelhecimento ou deterioração do inventário ao longo do tempo. Para tal, a melhor estimativa da empresa para as variáveis selecionadas foi utilizada (*forecast* da área financeira, estimativas da área de manufatura, objetivos definidos pelo time multifuncional para cada variável, entre outros).

A partir do fechamento contábil de cada período, os dados atualizados das variáveis selecionadas (mais relevantes para o propósito de predição) são adicionados ao conjunto original de dados coletados, formando um novo conjunto de dados expandido a cada período, e uma nova regressão PLS é conduzida mensalmente, conforme será detalhado na sequência deste trabalho nos passos 3.5.1 e 3.5.2.

#### 3.4. DEFINIR O CONJUNTO DE DIRETRIZES MAIS APROPRIADAS PARA REDUÇÃO DO INVENTÁRIO COM RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO

A quarta etapa do método proposto consiste na definição do conjunto de diretrizes mais apropriadas para redução do inventário com risco de obsolescência/deterioração. Esta etapa consiste na (i) definição do objetivo e da linha de base; (ii) definição do plano de ação consolidado e do calendário das reuniões periódicas.

##### 3.4.1. Revisar o objetivo e definir a linha de base

Um estudo de caso é uma investigação empírica que investiga um fenômeno contemporâneo dentro de seu contexto da vida real, especialmente quando os limites entre o fenômeno e o contexto não estão claramente definidos. Em posse de dados e informações detalhadas, e entendendo o conjunto de variáveis com maior impacto sobre a obsolescência ou deterioração do inventário, reúnem-se os objetivos para definição clara do objetivo do projeto (Yin, 2015).

A projeção do risco de obsolescência ou deterioração do inventário ao longo do tempo fornece subsídios para definição do objetivo do projeto, que deve traduzir de forma clara a intenção da empresa em reduzir o risco de obsolescência ou deterioração futura do inventário. Esta projeção, realizada com conjunto original de dados coletados, representa a estimativa do envelhecimento futuro do inventário com base na dinâmica de operação da empresa neste período, servindo como base para definição, em conjunto com o time multifuncional, de metas de redução do risco futuro de obsolescência ou deterioração do inventário.

De posse da projeção futura do risco de obsolescência ou deterioração do inventário, e observando o seu planejamento estratégico e/ou suas necessidades ou objetivos financeiros de



curto, médio e longo prazos, a empresa poderá validar ou redefinir os objetivos, as metas e os métodos para que o resultado ou efeito indesejado de um processo seja eliminado.

Para efeitos de comparação futura e monitoramento do objetivo previsto vs. realizado, o time multifuncional deverá definir a linha de base a partir da qual os objetivos serão mensurados. O referencial mais simples para definição de uma meta é uma linha de base, que são pontos de partida para medir a mudança de um determinado estado ou data, e são uma prática comum e amplamente aceita em áreas como medicina, economia, qualidade, meio ambiente e educação (Moldan et al., 2012, apud ten Brink, 2007; Therivel, 2012).

#### **3.4.2. Definir o plano de ação consolidado e o calendário das reuniões periódicas**

O plano de ação se faz necessário para coordenar e dar uma direção a um projeto, definindo onde se pretende chegar e o que se deseja alcançar. A definição das ações compreende o conhecimento da situação real e identificação dos pontos que apresentam deficiência. Os planos de ação devem ser tomados como guias e ser passíveis de replanejamento (Araújo et al., 2016). À medida em que as oportunidades de melhoria são identificadas é possível desenvolver um plano de ação com foco em resultados mais expressivos e eficientes, buscando a melhoria contínua do sistema (Santos e Miraglia, 2009, apud Garcia e Amaral, 2005).

A classificação dos itens em diferentes categorias e faixas de idade, a projeção do risco de obsolescência ou deterioração do inventário ao longo do tempo e os requisitos do planejamento estratégico e/ou das necessidades ou objetivos financeiros de curto, médio e longo prazos da empresa devem ser considerados na definição do plano de ação, o qual deve conter ações específicas para cada categoria ou faixa de idade, de forma que os métodos mais adequados de gestão sejam aplicados para cada grupo de itens, maximizando os resultados.

O plano de ação deve ser definido e validado pelo time multifuncional, deve ter um registro formal acessível a todas as áreas envolvidas no projeto e ser comunicado a toda a empresa para gerar engajamento. As ações devem ser definidas de forma sucinta, específica, realizável, realista e mensurável (Santos e Miraglia, 2009; Campos, 2009; Yin, 2015; Antony, 2006).

Quanto maior a prioridade do evento a ser analisado, mais rapidamente o processo de análise deve ser conduzido. Eventos de alta prioridade demandam equipes em tempo integral, porém as áreas envolvidas e a gestão da empresa devem ser mantidas informadas sobre o andamento do processo. Para tal, é recomendável prover uma demonstração visual de compromisso em nome da empresa através de reuniões periódicas agendadas com antecedência pelo time multifuncional. As reuniões devem ser realizadas de forma regular para que os projetos logrem

êxito em seus objetivos. As reuniões de revisão de resultados servem como um mecanismo para identificar os obstáculos do projeto e definir ações futuras, além de monitorar e divulgar o progresso feito pelo time multifuncional (Latino et al., 2006; Antony, 2006).

### 3.5. GESTÃO DA REDUÇÃO DO RISCO DE OBSOLESCÊNCIA OU DETERIORAÇÃO DO INVENTÁRIO

Para apoiar a melhoria contínua no gerenciamento do risco de obsolescência as empresas devem prover recursos adequados para apoiar atividades necessárias, de forma consistente com as necessidades do negócio. Para tal, um plano de gerenciamento de obsolescência deve ser melhorado continuamente, e o Ciclo PDCA é uma ferramenta adequada para este propósito (Bartels et al., 2012). Além de Bartels et al. (2012), Erlandsson & Duhan (2008) e Araújo et al. (2016) propuseram a utilização do Ciclo PDCA em programas de gestão de inventário com foco em obsolescência.

Esta etapa consiste em (i) coletar dados do processo e das variáveis escolhidas; (ii) projetar o estoque ao longo do tempo; (iii) atualizar os resultados e verificar a eficácia das ações; (iv) padronizar e revisar as ações corretivas, e; (v) rever os objetivos e estabelecer novas metas.

#### 3.5.1. Coletar dados atualizados

O Ciclo PDCA pressupõe coleta periódica de dados em um ciclo contínuo para chegar a melhoria contínua dos resultados (Santos e Miraglia, 2009). A partir do fechamento contábil de cada período, os dados atualizados das variáveis selecionadas (mais relevantes para o propósito de predição) são adicionados ao conjunto original de dados coletados, formando um novo conjunto de dados expandido a cada período. A coleta dos dados a cada fechamento contábil cabe responsável definido pela sua obtenção, observando os procedimentos previamente definidos (item 3.2.1). A adição dos dados mais recentes ao conjunto de dados original propicia estimativas futuras mais precisas (considerando o impacto de ações já implementadas), bem como a projeção em horizontes de tempo maiores à medida em que o conjunto de dados é expandido.

#### 3.5.2. Projetar o estoque

A previsão é uma questão central na elaboração de estratégias, dada a presunção de que o que pode ser previsto pode ser controlado. A previsão possibilita o controle, permitindo escolher os meios apropriados para alcançar os resultados desejados. Além disso, as previsões contribuem para que as empresas se mantenham na estratégia planejada, visto que permitem um posicionamento para o futuro, conduzindo as empresas a produzir resultados favoráveis

(Wiltbank et al., 2006). A análise de regressão é muito utilizada para previsão e tomada de decisão (Hair et al., 2009; Tabachnick e Fidell, 2007; Kettaneh et al., 2005).

À medida em que o conjunto de dados original é expandido a cada fechamento contábil, uma nova projeção deve ser realizada com base no conjunto expandido de dados, dando origem a uma nova equação de regressão a cada novo período adicionado. A projeção segue os mesmos passos já definidos no item 3.3.4 (regressão PLS com suporte do software Minitab).

Da mesma forma, a cada fechamento contábil, a nova melhor estimativa da empresa para as variáveis selecionadas deve ser considerada para efeitos de projeção (último *forecast* da área financeira, estimativas atualizadas da área de manufatura, novos objetivos definidos pelo time multifuncional para cada variável, entre outros). Estas novas estimativas devem considerar o efeito das ações definidas pelo time multifuncional sobre as variáveis selecionadas, ou seja, devem ser ajustadas às melhorias esperadas com as ações definidas no plano de ação consolidado, quando aplicável, visto que as novas estimativas das variáveis atualizadas a cada fechamento contábil são utilizadas para aplicação na nova equação de regressão e projeção dos resultados futuros.

### **3.5.3. Atualizar resultados e avaliar eficácia das ações**

O ciclo PDCA é utilizado em problemas cujas causas e contramedidas são conhecidas pelas organizações. Através da aplicação do método, o problema será delimitado, uma meta será estabelecida, as causas serão identificadas e ações corretivas serão implantadas, de forma a eliminar o problema de forma definitiva (Melo, 2001).

Como a previsão dos resultados futuros é ajustada a cada período, a partir da adição dos dados mais recentes ao conjunto de dados original, da nova projeção e da aplicação da nova equação de regressão (criada com base no novo conjunto expandido de dados), o resultado das ações implantadas pelo time multifuncional com efetividade no curto e médio prazos devem estar refletidas nos resultados obtidos a cada período, e o comparativo entre o resultado previsto vs. realizado a cada período deve evidenciar a eficácia das ações. Caso o resultado previsto no mês anterior não seja alcançado, o time multifuncional deve realizar uma análise de causa raiz das variações encontradas.

### **3.5.4. Padronizar e revisar ações corretivas**

Uma atividade importante do PDCA é a padronização dos processos identificados pelas fases anterior que tiveram resultados satisfatórios, para que sejam novamente aplicados em situações similares, consolidando o processo de melhoria contínua (Santos e Miraglia, 2009).

Com base na análise da eficácia das ações, o time multifuncional deve selecionar as ações sistêmicas que surtiram o efeito necessário no resultado e padroniza-las de acordo com as práticas de gestão de processo e/ou qualidade da empresa (inclusão em normas, procedimentos ou instruções de trabalho, no manual de boas práticas, no manual da qualidade, nos treinamentos específicos, entre outros), de forma que o resultado positivo desta ação se perpetue durante a operação regular da empresa.

Para as ações que não se mostrarem eficazes, após a análise de causa raiz das variações a cada período, o time multifuncional deve promover a sua revisão e, se necessário, alteração. Além disso, novas ações podem ser implantadas a cada período sempre que necessário, da mesma forma que ações que não se mostrarem efetivas devem ser eliminadas.

### **3.5.5. Rever objetivos e estabelecer novas metas**

O Ciclo PDCA parte do pressuposto da avaliação constante de todo o sistema como forma de detectar falhas, antecipando a ocorrência de eventos indesejados. Sua aplicação pressupõe um ciclo contínuo que busca a identificação dos pontos de melhoria do sistema, buscando a melhoria contínua dos resultados (Santos e Miraglia, 2009).

Após a revisão do plano de ação, o objetivo do projeto pode ser redefinido sempre que necessário pelos gestores da empresa ou pelo time multifuncional (com aprovação da gestão). A obtenção de resultados satisfatórios consecutivos pode tornar viável a definição de objetivos futuros mais arrojados, da mesma forma que insucessos frequentes podem demandar a definição de objetivos mais brandos, porém alcançáveis. Com esta dinâmica, o planejamento financeiro da empresa fica menos suscetível a resultados inesperados ou imprevistos.

## 4. ESTUDO DE CASO 1

### 4.1. CARACTERIZAÇÃO DA EMPRESA

Uma empresa multinacional fabricante de bens de consumo e bens de capital com duas fábricas no Brasil iniciou um projeto de redução do seu inventário no início deste ano por demanda de suas controladoras internacionais. O principal produto desta empresa é fabricado em sua fábrica na Região Norte do Brasil, e sua produção demanda um elevado percentual de componentes importados, fazendo com que o ciclo de compras e produção da empresa gire em torno de 150 dias. A venda deste produto é caracterizada pela sazonalidade acentuada, com maior volume vendas nos meses que antecedem o verão. Como a empresa possui capacidade limitada e insuficiente para atender à demanda do mercado nos meses de maior sazonalidade, costuma produzir um inventário de produtos acabados para estoque a partir da metade do ano.

Os principais clientes desta empresa são os grandes grupos varejistas nacionais, e a empresa enfrenta concorrência de outros fabricantes instalados no Brasil. Sendo assim, o mercado exige atualizações tecnológicas e de design constantes, fazendo com que a empresa renove sua linha de produtos em ciclos de aproximadamente dezoito meses. Neste ambiente, o planejamento adequado da introdução de novos produtos, bem como o correto controle do FIFO de produtos acabados são processos chave na gestão do inventário da empresa.

A crise econômica dos últimos anos no Brasil afetou o mercado do principal produto da empresa. O ciclo de compras e produção de aproximadamente 150 dias aliado à crise econômica conduziram a empresa a um cenário de inventário crescente a partir do último trimestre de 2014, tomando proporções ainda maiores no primeiro trimestre de 2015 devido ao período de baixa sazonalidade de vendas. Este inventário superou em muito as projeções da empresa para o período, e consumiu recursos de caixa importantes.

Entre as normas e processos contábeis e financeiros a que está sujeita a empresa, há uma que classifica o inventário em diferentes intervalos de idade, atribuindo risco crescente de perda ao inventário mais antigo por obsolescência, demandando a provisão em resultado de um percentual do valor de estoque dos itens com idade superior a 180 dias dentro do inventário total. De tal forma, em um cenário de inventário crescente, o resultado contábil da empresa ao final do exercício seria prejudicado caso contasse com uma parcela significativa de estoque com idade superior a 180 dias. Esta norma foi divulgada em agosto de 2014 e tornou-se efetiva a partir de janeiro de 2015.

A empresa definiu, em outubro de 2014, criar um grupo de trabalho com planos de ação e metas e responsáveis definidos para redução do inventário de produtos acabados e matérias primas, em especial a parcela do inventário com idade superior a 180 dias. Porém, os planos de ação para redução da idade do inventário, por si só, não foram suficientes para projetar a parcela de inventário que estaria acima de 180 dias no final de 2015, fundamental para prever o montante a ser provisionado para efeito de perdas no resultado contábil da empresa no exercício. Tal fato decorre de duas variáveis adicionais percebidas ao longo da análise do inventário da empresa: envelhecimento natural do inventário e as novas devoluções de produtos acabados.

A definição acerca do impacto do envelhecimento natural do inventário ao longo dos meses, e quanto este envelhecimento natural afetaria o inventário acima de 180 dias até o final do ano, mostrou-se muito complexa. Por regra, produtos que estejam em estoque a mais de 151 dias em determinado mês, e que não sejam vendidos dentro do mesmo mês, passam naturalmente a figurar no inventário acima de 181 dias do mês subsequente, estando, desde então, sujeitos a provisões de perda no resultado da empresa. A análise dos dados históricos de envelhecimento natural do estoque não levou a conclusões concretas, visto que se notou muita variação entre os meses, provavelmente devido à incerteza natural da venda e alterações nas dinâmicas de mercado e dos clientes.

A previsão de novas devoluções de produtos motivadas pelos clientes (por negociação comercial ou problemas de qualidade) ou pela logística de distribuição (atraso na entrega, danos de transporte ou sinistros de carga), também se mostrou bastante complexa, dada a imprevisibilidade dos problemas logísticos e do comportamento dos clientes. Por conta da complexidade da negociação com os clientes, do processo logística e da distância do principal mercado consumidor (Sudeste, Centro-Oeste e Sul do Brasil) até a principal fábrica (região Norte), muitas vezes o produto oriundo de devolução retorna aos armazéns ou centros de distribuição próximo ou acima de 180 dias de idade de inventário (medida a partir de sua data de fabricação). Esta parcela de inventário também se mostrou significativa, principalmente em função do aumento das devoluções de clientes devido à crise econômica no Brasil nos últimos anos.

Além disso, os resultados obtidos pelo grupo de trabalho de novembro de 2014 a abril de 2015 não foram satisfatórios, visto que, neste período, tanto o inventário total quanto a parcela com idade acima de 180 dias aumentaram neste período. Com base neste cenário, as controladoras internacionais da empresa exigiram um plano de ação robusto de redução do inventário com metas a serem alcançadas de abril a dezembro do referido ano, com foco na redução do

inventário acima de 180 dias, de forma a não penalizar ainda mais os resultados da empresa com provisões de perdas atribuídas a parcela de inventário mais antiga. Importante ressaltar que, no momento da identificação do problema, tanto as causas quanto as ações necessárias para resolver o problema não eram conhecidas pela empresa.

Para contornar estas dificuldades e conseguir montar uma projeção de inventário acima de 180 dias até o final deste ano, a empresa optou por desenvolver um método de previsão da idade do inventário ao longo do tempo, tendo como base ferramentas estatísticas e dados históricos de produção, planejamento, vendas, devoluções e registros contábeis de inventário. As cinco etapas do método proposto na seção 3 foram endereçadas pela empresa conforme os passos detalhados no decorrer deste capítulo.

## 4.2. APLICAÇÃO DO MÉTODO

### 4.2.1. Investigar os fatores que contribuem para o aumento da idade do inventário

#### 4.2.1.1. Identificar o problema

A crise econômica dos últimos anos, o período de baixa sazonalidade no segundo trimestre de 2015 e o ciclo de compras e produção de aproximadamente 150 dias conduziram a empresa a um cenário de inventário crescente, tanto de matérias primas quanto de produtos acabados, superando as projeções da empresa para o período e consumindo recursos de caixa importantes.

Por tratar-se de uma empresa multinacional, está sujeita a normas e processos contábeis e financeiros do padrão de contabilidade internacional IFRS, inclusive com relação a gestão do inventário. Dentre estas normas, há uma que classifica o inventário da empresa em diferentes intervalos de idade, atribuindo risco crescente de perda ao inventário mais antigo por quebra, danos ou obsolescência, o qual deve ser provisionado no resultado da empresa. Esta política foi introduzida em agosto de 2014, tendo como base a posição de inventário em cada período (mês) de apuração, e visa a motivar a empresa a reduzir seu inventário, em especial a parcela de itens com idade superior a 180 dias dentro do inventário total, a qual está sujeita a maiores riscos. As classes de idade do inventário e respectivo percentual de provisão estão listados na Tabela 1.

Idade do Inventário	0 a 30 dias	31 a 90 dias	91 a 180 dias	181 a 360 dias	361 a 720 dias	Mais de 720 dias
Provisão para perdas e obsolescência	0%	0%	0%	20%	40%	50%

Tabela 1: Classes de idade do inventário e provisão para perdas

Fonte: Dados da empresa

A empresa, como todo fornecedor de bens de consumo para redes varejistas, está sujeita a devolução de produtos que apresentam desempenho de venda abaixo do esperado no varejo,

estão em vias de serem substituídos por novos modelos ou por decorrência de negociação comercial. Porém, estes produtos, ao retornarem ao inventário da empresa, eram interpretados pelo sistema WMS (*Warehouse Management System* – Sistemas de Gerenciamento de Armazém) como um produto novo (recém-fabricado), visto que a maioria destes sistemas tem como padrão considerar a data de entrada dos produtos no armazém (e não a data de fabricação dos mesmos) para efeitos de FIFO. A lógica utilizada pelo sistema WMS, por estar em total contradição com a norma contábil que exige provisão de parte do valor do estoque acima de 180 dias como proteção contra obsolescência, gerou um grave problema de administração do inventário, levando à perda de performance na gestão do FIFO e conduzindo a um envelhecimento acima do esperado do inventário nos últimos meses.

O objetivo principal da implantação do método na empresa objeto do Estudo de Caso 1 foi a redução do inventário com idade superior a 180 dias até 31 de dezembro de 2015. A definição do problema de forma clara e objetiva por parte da empresa, incluindo o cenário de inventário crescente, o envelhecimento do inventário ao longo dos últimos meses, a necessidade de provisão nos resultados de uma parcela do inventário acima de 180 dias com impacto direto no resultado do exercício e a metodologia do sistema WMS para efeitos de FIFO foram fundamentais para que o projeto de redução do inventário com idade acima de 180 dias alcançasse êxito.

#### 4.2.1.2. Organizar o time multifuncional

A organização do time multifuncional ficou a cargo dos Diretores e Gerentes das áreas de Operações e Comercial da empresa. Cada uma das áreas diretamente afetadas pelo problema indicou um representante com conhecimento técnico, experiência e capacidade de resolução de problemas para participar do time multifuncional como recursos operacionais ou como especialistas nos assuntos relacionados à análise. O líder do projeto foi escolhido pelo Diretor de Operações da América Latina, e, pela natureza do problema, não foi necessária a participação de representantes de fornecedores. A responsabilidade de forçar a equipe enxergar outros pontos de vista e encontrar falhas na lógica fazendo perguntas persistentes ficou a cargo dos Gerentes de cada uma das áreas envolvidas, os quais participavam uma vez ao mês das reuniões de trabalho.

O time multifuncional definido pela empresa contou com a participação de 10 participantes, sendo dois da área de Produção (um para cada uma das fábricas), um da área de Logística de *Outbound*, um da área Financeira, dois do Planejamento Industrial, um da Engenharia de



Produtos, dois da área Comercial e um da área de Garantia e Pós-Vendas. Como líder do projeto foi escolhido o Diretor Regional de Operações.

A organização do time multifuncional com especialistas das áreas diretamente envolvidas no problema contribuiu de forma significativa para a identificação das regras e procedimentos aplicáveis a estoques obsoletos (etapa fundamental para garantir que as ações propostas considerem todo e qualquer requisito aplicável a estoque obsoleto na indústria em questão) e para que as ações propostas ao longo do projeto alcançassem o resultado esperado.

#### 4.2.1.3. Identificar regras e procedimentos aplicáveis a estoques obsoletos ou deteriorados

As normas, procedimentos, políticas, questões regulatórias ou exigências de clientes aplicáveis a estoques obsoletos foram obtidas através de uma atividade de *brainstorming* e entrevistas com o time multifuncional e especialistas das áreas diretamente envolvidas no problema, para assegurar que nenhum requisito tenha ficado de fora do processo. Dentre os fatores identificados, o de maior impacto direto no resultado é a política de classificação do inventário da empresa em diferentes intervalos de idade. A política de aprovação de devoluções de clientes (concessões comerciais) foi considerada como o segundo maior fator em termos de impacto no resultado, seguida pelo método de gestão do FIFO. A ausência de política comercial e de gestão de estoques de produtos descontinuados foi considerada de peso relevante no problema.

Outras regras observadas dizem respeito à contabilização de baixas de estoque, gestão da introdução de novos produtos (gestão de portfólio), política de cancelamento de pedidos de produtos com especificações especiais (comum na linha de produtos de bens de capital), procedimento de gestão dos produtos danificados nos armazéns e centros de distribuição (por problemas de manuseio e movimentação), política de controle de devolução de produtos danificados no transporte, processo de planejamento de produção produtos modulares que devem ser vendidos em conjunto, processo de planejamento e compra de componentes para produtos com especificações especiais, processo de retrabalho de produtos devolvidos ou danificados nos armazéns e centros de distribuição e processo de retrabalho de produtos com problemas de produção ou de qualidade de componentes, processo de gestão do agendamento de entregas para clientes (fonte de devolução de pedidos devido à perda da janela de entrega), política de estoque de peças de reposição, e política de segregação de itens no estoque em diferentes armazéns de acordo com a disponibilidade dos mesmos para venda (definição de locais para produtos disponíveis para venda, bloqueados por qualidade ou decorrentes de devolução de clientes).

#### 4.2.1.4. Identificar fatores que podem gerar estoque obsoleto ou deteriorado

A identificação dos fatores que podem gerar estoque obsoleto foi realizada de duas formas. Primeiramente, foi realizada uma atividade de *brainstorming* com o time multifuncional e especialistas das áreas diretamente envolvidas no problema. Em um segundo momento, o time multifuncional e os especialistas das áreas diretamente envolvidas no problema analisaram uma listagem de itens obsoletos e descontinuados que continuavam no estoque da empresa, segregaram os produtos em grupos e aplicaram o método dos 5 porquês nos grupos cuja causa da obsolescência não estava clara.

Os fatores elencados pelo grupo como principais geradores do estoque obsoleto da empresa foram o método de gestão do FIFO nos armazéns, o grande volume de devolução de clientes, a introdução de novos produtos antes de eliminar (ou reduzir drasticamente) o estoque dos produtos atuais que seriam substituídos, o descasamento de estoque de produtos modulares que devem ser vendidos em conjunto (devido a danos no transporte, danos por movimentação interna nos armazéns, problemas de qualidade ou planejamento inadequado da produção), a ausência de uma política de venda específica para produtos com baixo giro de estoque, a ausência de política de vendas diferenciada para produtos descontinuados e a falta de gestão dos produtos devolvidos por danos no transporte ou por movimentação interna nos armazéns.

#### **4.2.2. Classificar o estoque em faixas de idade para mensurar o risco de obsolescência ou deterioração do inventário**

##### 4.2.2.1. Coletar dados

Após o estudo inicial, foram definidos os dados a serem coletados de forma a munir o time multifuncional com os dados e informações necessárias para determinação das causas do problema. Foram coletados dados do sistema ERP, dos relatórios da área Financeira e dos indicadores das áreas de Produção, Comercial, e Planejamento Industrial, Logística de Distribuição, Almoxarifado e Engenharia de Produtos. Foram definidos responsáveis dentro do time multifuncional por coletar os dados mensalmente e disponibilizar em um diretório de uso comum do projeto. Em algumas situações, novos relatórios foram criados no sistema ERP para munir o time multifuncional dos dados necessários para investigação, como, por exemplo, um relatório que classificava o estoque em faixas de idade de acordo com a data de produção dos itens. Os principais dados coletados estão listados no Quadro 4.

DADO	DEFINIÇÃO	OBJETIVO PRELIMINAR
Venda do período	Venda apurada em cada um dos períodos (meses), aberta por itens, em dólares sem impostos	Avaliar a relação entre o volume de vendas e o envelhecimento do inventário
Venda de sucata de produtos do período	Venda de sucata de produtos em cada um dos períodos (meses) em dólares sem impostos	Avaliar a performance da venda de produtos sucateados
Volume de produção do período	Produção realizada em cada um dos períodos (meses) em horas-padrão de produção (CSH – Cost Standard Hours)	Avaliar a relação entre o volume de produção e o envelhecimento do inventário
Produção do período	Produção realizada em cada um dos períodos (meses), aberta por itens, em unidades	Avaliar a relação entre o volume de produção e o envelhecimento do inventário
Produtos descasados na produção	Quantidade de produtos modulares produzidos descasados no final de cada um dos períodos (meses) em unidades	Avaliar o impacto do descasamento de produtos no planejamento de produção e na produção no envelhecimento do inventário
Tempo médio de casamento de produtos modulares	Tempo médio entre a produção de módulos complementares na produção a cada período	Avaliar o impacto do tempo necessário para disponibilizar todos os módulos necessários para venda no envelhecimento do inventário
Volume de retrabalho de produtos no período	Quantidade de produtos indisponíveis para venda retrabalhados em cada um dos períodos (meses) e disponibilizados para venda	Avaliar o impacto da performance do retrabalho de produtos na produção no envelhecimento do inventário
Inventário total por item	Total de inventário do período por item em dólares	Avaliar o comportamento do inventário ao longo do tempo
Inventário de produtos acabados por faixa de idade	Total de inventário de produtos acabados aberto por item e por faixas de idade em cada um dos períodos (meses) em dólares	Avaliar o ritmo em que o inventário está envelhecendo ao longo do tempo
Inventário de produtos descasados	Total de produtos descasados no estoque em cada um dos períodos (meses), aberto por item, em unidades	Avaliar o impacto do descasamento de produtos no envelhecimento do inventário
Causas do descasamento do estoque	Identificação da causa raiz mais provável de cada produto descasado no estoque em cada um dos períodos (meses)	Avaliar as principais causas de descasamento de estoque
Inventário de produtos indisponíveis para venda	Total de produtos indisponíveis para venda no inventário em cada um dos períodos (meses), aberto por item, em dólares	Avaliar o impacto do estoque de produtos indisponíveis para venda no envelhecimento do inventário
Causas do estoque de produtos indisponíveis para venda	Identificação da causa raiz mais provável de cada produto indisponível para venda no estoque em cada um dos períodos (meses)	Avaliar as principais causas de produtos indisponíveis para venda no estoque
Performance do FIFO	Percentual de itens faturados corretamente, obedecendo às regras do FIFO (lotes mais antigos primeiro)	Avaliar se a Expedição está cumprindo as regras de separação de itens para faturamento seguindo os critérios do FIFO
Devoluções de produtos acabados	Total de itens devolvidos independentemente do motivo em cada um dos períodos (meses) em dólares sem impostos	Avaliar a relação entre o volume de devoluções e o envelhecimento do inventário
Motivos de devoluções de produtos acabados	Identificação da causa raiz mais de cada produto acabado devolvido para o estoque em cada um dos períodos (meses)	Avaliar as principais causas de devolução de produtos
Performance da introdução de novos produtos	Saldo de estoque de produtos descontinuados após a introdução de novos produtos, em dólares	Avaliar a efetividade do planejamento de introdução de novos produtos

Quadro 4: Dados coletados pelo time multifuncional a cada período (mensal)

Fonte: Dados da empresa

A coleta de dados foi realizada pelo time multifuncional e especialistas das áreas envolvidas na aplicação do método proposto, utilizando-se do conhecimento prévio dos participantes das rotinas e variáveis que compõe o processo de gestão de inventário.

Os dados foram retirados do sistema ERP e dos reportes da área Financeira no período compreendido entre setembro de 2014 e abril de 2015, e seu conjunto foi definido como o conjunto original dos dados, posteriormente utilizada para identificar as variáveis mais relevantes. Devido a mudanças de sistema e de registro de dados realizados pela área Financeira da empresa em setembro de 2014, não foi possível resgatar do sistema ERP ou dos reportes da

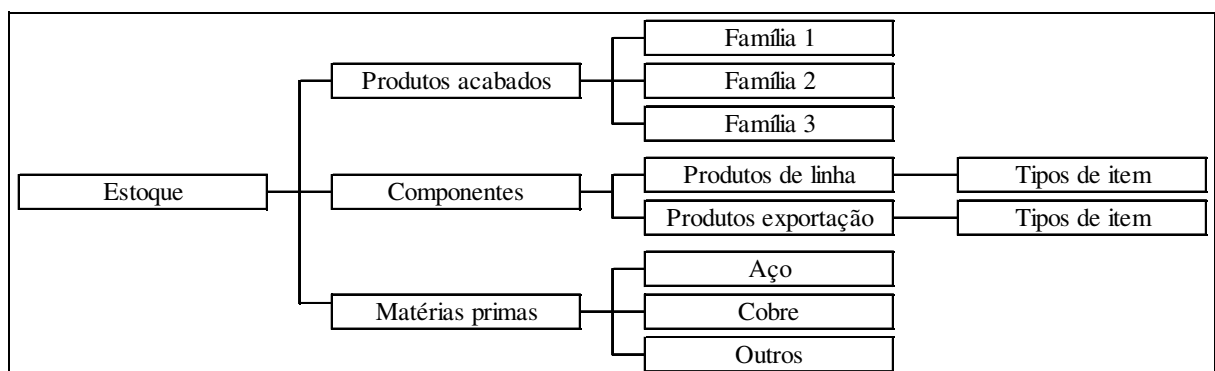
área Financeira dados anteriores a esta data que refletissem os dados relacionados no Quadro 4.

A coleta de dados foi facilitada pela organização e disponibilidade dos dados no sistema ERP da empresa e nos reportes da área Financeira. A única restrição foi com relação com relação aos dados de idade do inventário, os quais só estavam disponíveis a partir de setembro de 2014 devido a uma alteração de sistema realizada pela área Financeira que não permitiu a consolidação dos dados anteriores a esta data em um formato onde pudesse ser extraída a idade do inventário, o que limitou os dados disponíveis para análise a um período de oito meses.

#### 4.2.2.2. Classificar o estoque por tipo de item

A classificação dos itens em categorias foi necessária para interpretação mais precisa dos dados e para definir os métodos mais adequados de gestão para cada categoria. A classificação do inventário por tipo de item foi feita com base nos parâmetros do cadastro de itens do sistema ERP da empresa.

Originalmente, os itens poderiam ser classificados conforme o cadastro de itens do sistema ERP, que propiciava a segregação entre produtos acabados, componentes e matérias primas. Os produtos acabados poderiam ser classificados em famílias de produto (sendo que a empresa contava com três famílias principais). Os componentes, por sua vez, poderiam ser divididos entre itens para montagem de produtos de linha normal e itens para fabricação de produtos para exportação, e cada uma destas classes poderia ser novamente classificada em função do tipo de item (componentes plásticos, componentes metálicos, motores, componentes elétricos, etc.). Por fim, as matérias primas poderiam ser classificadas conforme o seu tipo, sendo os principais aço e cobre. A classificação original dos itens no sistema ERP pode ser observada no Quadro 5.



Quadro 5: Classificação original dos itens no sistema ERP

Fonte: Dados da empresa

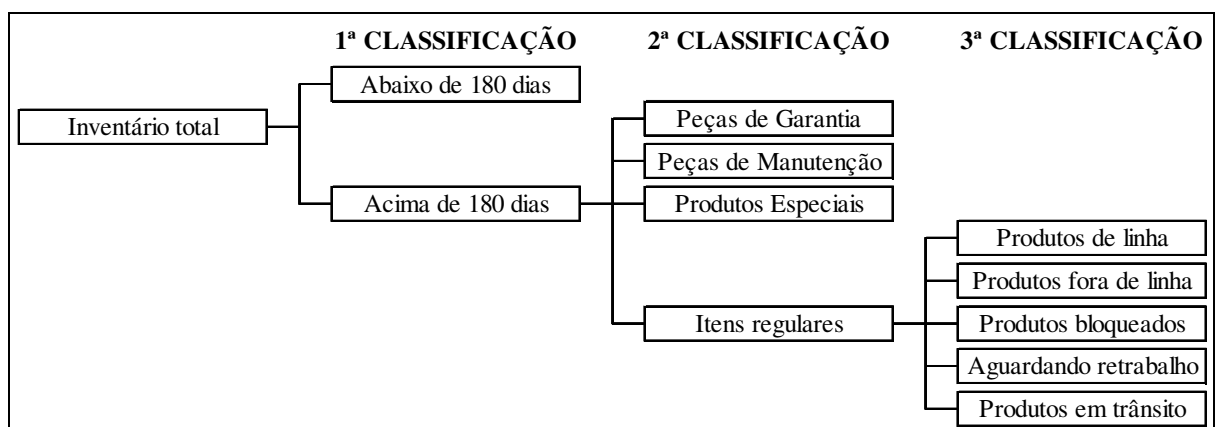
Para a análise desejada, porém, fez-se necessário criar novas classificações em função da situação de cada item no inventário. Esta nova classificação foi realizada com base no conhecimento dos especialistas da empresa em cada uma das áreas envolvidas no problema, considerando os dados de inventário coletados no sistema ERP.

A primeira classificação teve como objetivo classificar o inventário em dois grupos com relação ao tempo em inventário, sendo o primeiro grupo formado por itens com tempo de estoque inferior a 180 dias, e o segundo grupo por itens com tempo de estoque superior a 180 dias. Os itens em estoque a mais de 180 dias foram segregados e considerados parte do estudo.

A segunda classificação foi feita de forma excluir da análise os estoques de peças da Garantia e de Manutenção e o estoque de peças para produção de produtos especiais. Estas três categorias, obviamente, contam com estoque de itens com idade acima de 180 dias, porém possuem um propósito específico e foram retiradas do escopo da análise.

A terceira classificação classifica os itens regulares, escopo da análise, com base no seu status, sendo eles, produtos de linha (produtos que ainda estão em produção), produtos fora de linha (produtos que deixaram de ser produzidos), produtos bloqueados (por qualidade, indisponíveis para venda), produtos aguardando retrabalho (categoria que inclui os produtos modulares descasados) e produtos em trânsito (produtos que estão em transporte no momento do ponto de corte dos relatórios, e que ainda não foram enquadrados nas classes anteriores).

Desta forma, à classificação original do sistema ERP poderia ser aplicada uma nova classificação em três níveis, a qual considera a situação dos itens no inventário, e que proporciona uma análise profunda da contribuição de cada item para o risco de obsolescência do inventário, bem como definir ações específicas para cada item em particular. Esta nova classificação pode ser observada no Quadro 6.



Quadro 6: Classificação dos itens conforme a sua situação no inventário  
Fonte: Dados da empresa

A classificação inicial do estoque por tipo de item obtida diretamente do sistema mostrou-se insuficiente para a análise desejada, no que diz respeito a idade do inventário e a situação dos itens do inventário com relação ao portfólio oferecido aos clientes. Outra classificação necessária para aplicação do método diz respeito a exclusão dos itens que não serão alvo da análise. Mesmo considerando que o objetivo é a redução do montante de inventário com idade acima de 180 dias, não é prudente considerar nesta análise o estoque de peças de manutenção (sob risco de parada de máquina por tempo maior do que o desejado), o estoque de peças de reposição para o Pós Vendas (sob risco de não atender a demanda de clientes para manutenção de seus produtos), e o estoque de componentes para fabricação de produtos especiais (sob risco de perder vendas de produtos especiais devido ao longo lead time para aquisição de componentes). A classificação dos itens para manutenção, pós-vendas e produtos especiais foi realizada manualmente, utilizando o software Excel sobre a base de dados do inventário da empresa. Não houve necessidade de utilização da análise discriminante para classificação dos itens de manutenção, pós-vendas e produtos especiais, visto que os itens de manutenção e pós-vendas estavam armazenados em local de estoque específico no sistema ERP (estoque de manutenção), e os itens de produtos especiais continham parâmetros específicos de planejamento no sistema ERP (planejamento de compras por ponto de ressuprimento, não por MRP – *Material Requirement Planning*).

#### 4.2.2.3. Classificar o estoque em faixas de idade

A classificação do inventário em faixas de idade teve como objetivos atender aos requisitos das controladoras internacionais quanto ao risco associado à idade do inventário e determinar medidas precisas para redução do risco de obsolescência específicas para cada item e faixa de idade. Para os produtos acabados, a classificação foi realizada com base nos registros contábeis de inventário, através do registro dos números de série (atrelados ao lote e data de produção). As faixas de idade para classificação do inventário foram definidas de acordo com os requisitos das controladoras internacionais, conforme apresentado na Tabela 1.

O conhecimento da idade do inventário por item e faixa de idade é um pré-requisito para redução do inventário acima de 180 dias, e a maioria dos sistemas ERP das indústrias não possui esta informação prontamente disponível. Sua obtenção demandou o cruzamento de dados do sistema, como códigos dos produtos acabados, números de série dos produtos em estoque e datas de fabricação das ordens de produção. A classificação do inventário em faixas de idade foi obtida automaticamente através de um novo relatório criado no sistema.

### **4.2.3. Definir o conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo**

#### 4.2.3.1. Estudar o processo e variáveis

O time multifuncional realizou uma análise preliminar do processo a partir dos dados coletados, de forma a definir quais características do processo possuíam maior relevância no envelhecimento do inventário, estabelecer quais questões demandam maior profundidade de estudo e quais variáveis se mostram mais relevantes para o processo. O foco principal da análise foi o inventário de produtos acabados, visto que representava 69% do inventário total da empresa. Os instrumentos utilizados foram observação, análises de registros, arquivos e relatórios do sistema ERP (contemplando diferentes fontes de dados), observação direta dos processos e entrevistas com especialistas das áreas envolvidas no processo.

#### 4.2.3.2. Definir as variáveis

Após a análise do processo e suas variáveis, o conjunto de variáveis julgadas de maior relevância sobre o envelhecimento do inventário foi identificado pelo time multifuncional, especialistas das áreas e funcionários que operam diretamente nas principais atividades do processo observado. Os dados utilizados para análise inicial são relativos ao período compreendido entre setembro de 2014 e abril de 2015, e compreendem o conjunto original de dados coletados, utilizado para efeitos de projeção.

As primeiras análises foram feitas com regressão linear em Excel, combinando diferentes variáveis, buscando a modelagem da variável dependente (y) por meio de um conjunto de variáveis independentes (x), com o único propósito de buscar um melhor entendimento das variáveis pelo time multifuncional. A Tabela 2 mostra as diferentes combinações utilizadas para cálculo do impacto do envelhecimento natural do inventário e das devoluções no inventário de produtos, em um total de sete análises (1 a 7).

ANÁLISE	FERRAMENTA	VARIÁVEIS	RESULTADO (R <sup>2</sup> )
1	Regressão linear	X1 = Venda do período X2 = Produção do período Y = Envelhecimento do inventário no período	0,5857
2	Regressão linear	X1 = Variação da venda (mês atual dividido pelo mês anterior) X2 = Variação da produção (mês atual dividido pelo mês anterior) Y = Variação do envelhecimento do inventário (mês atual dividido pelo mês anterior)	0,0962
3	Regressão linear	X1 = Variação da venda (mês atual dividido pelo mês anterior) X2 = Variação da produção (mês atual dividido pelo mês anterior) Y = Envelhecimento do inventário no período	0,0939
4	Regressão linear	X1 = Venda do período X2 = Produção do período Y = Variação do envelhecimento do inventário (mês atual dividido pelo mês anterior)	0,5906
5	Regressão linear	X1 = Inventário abaixo de 180 dias no período X2 = Produção do período Y = Envelhecimento do inventário no período	0,4303
6	Regressão linear	X1 = Inventário abaixo de 180 dias no período X1 = Variação da produção (mês atual dividido pelo mês anterior) Y = Variação do envelhecimento do inventário (mês atual dividido pelo mês anterior)	0,3336
7	Regressão linear	X1 = Inventário total do período X2 = Produção do período Y = Envelhecimento do inventário no período	0,6617

Tabela 2: Projeção do envelhecimento do estoque de produtos acabados através de regressão linear em Excel

Fonte: Dados da empresa

Após a análise com regressão linear, o time multifuncional optou por realizar análises com variáveis adicionais com o objetivo de obter resultados mais robustos. O diferencial no resultado foi obtido principalmente com a introdução de duas variáveis específicas que contribuíram sobremaneira para robustez do resultado final, sendo elas (i) o inventário de produtos acabados com idade inferior a 180 dias e (ii) a performance do FIFO. A Tabela 3 mostra as diferentes combinações utilizadas para cálculo do impacto do envelhecimento natural do inventário e das devoluções no inventário de produtos acabados através de regressão linear múltipla, em um total de nove análises (8 a 16).



ANÁLISE	FERRAMENTA	VARIÁVEIS	RESULTADO ( $R^2$ )
8	Regressão múltipla	X1 = Inventário total do período X2 = Venda do período X3 = Produção do período X4 = Devoluções do período Y = Variação do envelhecimento do inventário (mês atual dividido pelo mês anterior)	0,6577
9	Regressão múltipla	X1 = Inventário total do período X2 = Venda do período X3 = Produção do período X4 = Devoluções do período Y = Envelhecimento do inventário no período	0,6689
10	Regressão múltipla	X1 = Inventário acima de 90 dias no período X2 = Venda do período X3 = Produção do período X4 = Devoluções do período Y = Envelhecimento do inventário no período	0,6493
11	Regressão múltipla	X1 = Inventário abaixo de 180 dias no período X2 = Venda do período X3 = Produção do período X4 = Devoluções do período Y = Envelhecimento do inventário no período	0,6690
12	Regressão múltipla	X1 = Inventário abaixo de 180 dias no período X2 = Venda do período X3 = Produção do período X4 = Devoluções do período Y = Variação do envelhecimento do inventário (mês atual dividido pelo mês anterior)	0,6579
13	Regressão múltipla	X1 = Inventário abaixo de 180 dias no período X2 = Venda do período X3 = Devoluções do período Y = Envelhecimento do inventário no período	0,6382
14	Regressão múltipla	X1 = Inventário abaixo de 180 dias no período X2 = Venda do período X3 = Produção do período Y = Envelhecimento do inventário no período	0,6408
15	Regressão múltipla	X1 = Inventário abaixo de 180 dias no período X2 = Produção do período X3 = Devoluções do período Y = Variação do envelhecimento do inventário (mês atual dividido pelo mês anterior)	0,5256
16	Regressão múltipla	X1 = Inventário abaixo de 180 dias no período X2 = Venda do período X3 = Produção do período X4 = Devoluções do período X5 = Performance do FIFO no período Y = Envelhecimento do inventário no período	0,8036

Tabela 3: Projeção do envelhecimento do estoque de produtos acabados através de regressão múltipla em Excel

Fonte: Dados da empresa

O melhor resultado foi obtido através de regressão múltipla utilizando a combinação de 5 variáveis para projeção do envelhecimento natural do inventário e devoluções de produtos acabados, obtendo-se um  $R^2$  de 0,80 (análise 16). Os dados utilizados para a análise estão na Tabela 4. Dada a política de confidencialidade da empresa, os valores das variáveis apresentados na tabela abaixo são meramente ilustrativos, porém mantêm a correta proporcionalidade entre si para efeitos de análise.

PERÍODO	INVENTÁRIO <180 DIAS (X1)	VENDA (X2)	PRODUÇÃO (X3)	DEVOLUÇÕES (X4)	FIFO (X5)	ENVELHECIMENTO (Y)
set/14	107.445	98.357	377.491	3.577	0,67	2.012
out/14	106.988	110.052	404.900	1.955	0,67	1.943
nov/14	94.056	106.602	353.277	1.938	0,67	522
dez/14	68.877	102.230	255.309	2.307	0,67	2.820
jan/15	75.604	51.031	242.027	2.007	0,67	1.485
fev/15	68.231	64.811	218.947	1.940	0,67	607
mar/15	84.792	52.509	283.289	3.210	0,77	486
abr/15	103.965	37.502	235.986	6.230	0,80	3.188
mai/15	106.940	32.460	133.825	3.860	0,81	2.034

Tabela 4: Dados utilizados na regressão múltipla da análise 16 da Tabela 3

Fonte: Dados da empresa

Com base nos dados da tabela 4, a análise por regressão múltipla forneceu as informações apresentadas na Quadro 7.

RESUMO DOS RESULTADOS			
<i>Estatística de regressão</i>		<i>Coefficientes</i>	
R múltiplo	0,896417722	Interseção	19121,11752
R-Quadrado	0,803564732	Variável X 1	0,062039087
R-quadrado ajustado	0,476172619	Variável X 2	-0,073985518
Erro padrão	1394,869716	Variável X 3	0,000947145
Observações	9	Variável X 4	0,631472542
		Variável X 5	-29384,29673

Quadro 7: Resultados da análise de regressão múltipla com dados da Tabela 4 em Excel

Fonte: Dados da empresa

O coeficiente de determinação  $R^2$  obtido através da correlação múltipla em Excel se mostrou satisfatório (0,8035), porém, o valor do coeficiente  $R^2$  ajustado (0,4761) apresentou diferença relevante, indicando a inclusão indiscriminada de variáveis que estão prejudicando o princípio da parcimônia. O  $R^2$  ajustado é uma abordagem bastante simples para a seleção entre um conjunto de modelos que contêm diferentes números de variáveis, visto que o valor do  $R^2$  ajustado é afetado pelo poder explicativo e pelos graus de liberdade das variáveis. O resultado obtido indica que o melhor ajuste está relacionado apenas a um subconjunto das variáveis independentes utilizadas, tornando necessário definir um novo modelo através de técnicas de seleção de variáveis, buscando obter um modelo com maior  $R^2$  ajustado, contendo apenas variáveis corretas e sem variáveis de ruído. Esta análise preliminar em Excel conduziu o time multifuncional a um melhor entendimento da relação das variáveis com o problema em estudo.

#### 4.2.3.3. Selecionar as variáveis mais relevantes para o propósito de predição

O valor do coeficiente  $R^2$  ajustado indicou a necessidade de reduzir o número de variáveis para obtenção de um modelo de previsão mais rápido, de menor complexidade e com melhores propriedades estatísticas, e que demande a coleta de um menor número de dados e a utilização de menor quantidade de recursos de processamento e armazenamento de informações. Para

alcançar este objetivo, o time multifuncional optou por uma nova análise da correlação entre as variáveis utilizando um programa de computador mais adequado para análises estatísticas, no caso, o Minitab, através da regressão PLS. Para tornar a definição do conjunto de variáveis mais robusta, a comparação entre as variáveis controláveis no Minitab foi feita inicialmente de forma codificada, ou seja, padronizando-se os intervalos dos termos entre -1 (nível baixo) e +1 (nível alto). A Tabela 5 contém os dados da Tabela 4 codificados para efeito de análise.

PERÍODO	INVENTÁRIO <180 DIAS (C1)	VENDA (C2)	PRODUÇÃO (C3)	DEVOLUÇÕES (C4)	FIFO (C5)	ENVELHECIMENTO (Y)
set/14	1,00	1,00	1,00	-1,00	-1,00	-0,70
out/14	0,30	0,90	0,70	-1,00	-1,00	0,10
nov/14	-1,00	0,80	0,20	-0,80	-1,00	-1,00
dez/14	-0,60	-0,50	0,10	-1,00	-1,00	0,40
jan/15	-1,00	-0,20	0,00	-1,00	-1,00	0,10
fev/15	-0,20	-0,50	0,30	-0,40	0,30	0,10
mar/15	0,80	-0,90	0,10	1,00	0,80	1,00
abr/15	1,00	-1,00	-0,50	-0,10	1,00	0,60
mai/15	0,10	-0,90	-1,00	-0,90	0,50	-0,30

Tabela 5: Dados codificados utilizados na regressão PLS em Minitab  
Fonte: Dados da empresa

O resultado da análise realizada em Minitab com os dados da Tabela 5 são mostrados no Quadro 8.

Regression Analysis: Y versus C1; C2; C3; C4; C5				
The regression equation is				
Y = - 0,022 + 0,359 C1 - 0,988 C2 + 0,245 C3 + 0,526 C4 - 0,722 C5				
Predictor	Coef	SE Coef	T	P
Constant	-0,0224	0,2714	-0,08	0,938
C1	0,3587	0,2474	1,45	0,221
C2	-0,9881	0,3918	-2,52	0,065
C3	0,2446	0,5129	0,48	0,658
C4	0,526	0,3579	1,47	0,216
C5	-0,7217	0,4308	-1,68	0,169
S = 0,405282		R-Sq = 80,7%		R-Sq(adj) = 56,6%

Quadro 8: Resultados da análise de regressão PLS com dados codificados da Tabela 5 em Minitab  
Fonte: Dados da empresa

Observou-se novamente, na análise em Minitab (Quadro 8), uma diferença relevante entre os coeficientes  $R^2$  (0,807) e  $R^2$  ajustado (0,566), indicando a inclusão indiscriminada de variáveis. A redução das variáveis foi obtida utilizando regressão PLS com o método *Best Subset Selection* (BSS), utilizando o  $R^2$  ajustado e critério Cp de Mallows para selecionar o melhor modelo com relação ao erro de teste. O resultado desta análise é apresentado no Quadro 9.

Best Subsets Regression: C6 versus C1; C2; C3; C4; C5									
Response is Y									
Mallows					C C C C C				
Vars	R-Sq	t-Sq(adj)	Cp		1	2	3	4	5
1	46,5	39,8	5,1	0,4775				X	
1	28,7	19,8	8,8	0,55118		X			
2	59,5	47,9	4,4	0,44417	X	X			
2	53,4	40,1	5,7	0,47637	X		X		
3	65,6	48,4	5,1	0,44224	X	X	X		
3	65,2	47,8	5,2	0,44468	X		X	X	
4	79,6	63,3	4,2	0,37266	X	X		X	X
4	70,6	47,1	6,1	0,44769	X	X	X	X	
5	80,7	56,6	6	0,40528	X	X	X	X	X

Quadro 9: Resultados da análise através da função *Best Subset* em Minitab

Fonte: Dados da empresa

O Quadro 9 mostra que o melhor resultado é obtido através da utilização de quatro variáveis (C1, C2, C4 e C5), com o melhor resultado de  $R^2$  ajustado (0,633) e o menor Cp (4,2). Pode-se chegar a esta mesma conclusão sem a utilização da função “*Best Subset*” do Minitab, através da eliminação das variáveis com maior número-p.

Enquanto a variável C2 (venda) representa o volume de negócios da empresa, a variável C1 (inventário menor do que 180 dias) representa uma característica da operação com capacidade de absorver, até determinado ponto, variações na variável C2. A variável C4 (devoluções) representa uma característica do negócio da qual a empresa não possui controle total (depende das condições do mercado e da economia, problemas de qualidade e de instalação do produto no campo, dos critérios de aceitação dos clientes e do desempenho de venda dos varejistas), mas que afeta diretamente o risco de obsolescência futura, visto que os registros históricos da empresa evidenciam que os produtos devolvidos retornam ao estoque da empresa vários meses após a compra. Por fim, a variável C5 (FIFO), representa um processo interno da empresa sob a qual ela detém total controle, mas cuja importância vinha sendo negligenciada pela gestão da empresa e pela área de gestão de estoques, e cujo desempenho afeta diretamente o risco de obsolescência dos produtos.

A partir da definição do conjunto ideal de variáveis, uma nova análise foi feita em Minitab utilizando os dados reais não codificados e o conjunto de variáveis sugerida pela função “*Best Subset*” do Minitab, apresentados na Tabela 6. Os resultados desta análise são apresentados no Quadro 10.

PERÍODO	INVENTÁRIO <180 DIAS (C1)	VENDA (C2)	DEVOLUÇÕES (C4)	FIFO (C5)	ENVELHECIMENTO (Y)
set/14	107.445	98.357	3.577	0,67	2.012
out/14	106.988	110.052	1.955	0,67	1.943
nov/14	94.056	106.602	1.938	0,67	522
dez/14	68.877	102.230	2.307	0,67	2.820
jan/15	75.604	51.031	2.007	0,67	1.485
fev/15	68.231	64.811	1.940	0,67	607
mar/15	84.792	52.509	3.210	0,77	486
abr/15	103.965	37.502	6.230	0,80	3.188
mai/15	106.940	32.460	3.860	0,81	2.034

Tabela 6: Dados reais utilizados na regressão em Minitab após a aplicação da ferramenta *Best Subset*

Fonte: Dados da empresa

Regression Analysis: Y versus C1; C2; C4; C5				
The regression equation is				
Y = 22050 + 0,0583 C1 - 0,0692 C2 + 0,893 C4 - 34365 C5				
Predictor	Coef	SE Coef	T	P
Constant	22050	10284	2,14	0,085
C1	0,05829	0,03437	1,7	0,151
C2	-0,0692	0,02548	-2,72	0,042
C4	0,8931	0,4041	2,21	0,078
C5	-34365	14487	-2,37	0,064
S = 1168,30		R-Sq = 78,3%		R-Sq(adj) = 61,0%

Quadro 10: Resultados da análise de regressão com dados reais da Tabela 6 em Minitab

Fonte: Dados da empresa

A redução do número de variáveis foi fundamental para que o time multifuncional pudesse focar nas variáveis com maior impacto sobre o resultado, reduzir o tempo de coleta e análise de dados, direcionar as ações e prover maior controle sobre os processos e atividades que impactam diretamente nas variáveis selecionadas.

#### 4.2.3.4. Projetar o estoque ao longo do tempo

O modelo de previsão utilizado para desenvolver alertas precoces e direcionar ações apropriadas para evitar o envelhecimento do inventário e reduzir o risco de obsolescência foi obtido através da análise de regressão no Minitab com a utilização da função “*Best Subset*”. A projeção do inventário futuro da empresa de junho a dezembro de 2015 pode ser obtida através da equação (18).

$$Y = 22050 + 0,0583c_1 - 0,0692c_2 + 0,893c_4 - 34365c_5 \quad (18)$$

Para a projeção dos resultados futuros (junho a dezembro de 2015), foram utilizadas as seguintes premissas para os fatores utilizados na análise por regressão PLS:

- a) Inventário menor do que 180 dias (C1): Utilizado a última previsão (*forecast*) de inventário da empresa (em dólares), aplicando sobre ele todas as ações já endereçadas de redução do inventário até dezembro. Para efeito de cálculo da parcela inferior a 180 dias, partiu-se do pressuposto que as ações implantadas atingiriam seus objetivos de redução do estoque superior a 180 dias, logo, a diferença entre o inventário total esperado para o final do ano e a parcela remanescente acima de 180 dias projetada pelos planos de ação resultaria na parcela de inventário abaixo de 180 dias.
- b) Venda (C2): Utilizado a última previsão (*forecast*) de vendas da empresa (em dólares);
- c) Devoluções (C4): Foi feito um mapeamento de todas as devoluções em análise e uma projeção das devoluções futuras mês a mês (em dólares), com base na implantação de uma política mais restritiva de aprovação de devoluções e restrição do total de devoluções em determinado período a um percentual máximo sobre as vendas do mesmo período. Planos de ação específicos foram implantados para garantir que as devoluções futuras se mantenham dentro dos percentuais projetados.
- d) FIFO (C5): Foi feita uma projeção de melhoria da performance do FIFO (%) em todos os armazéns e centros de distribuição até o final do ano, com base nos planos de ação já implantados. Considerou-se, porém, um risco de insucesso no processo de FIFO nos dois maiores centros de distribuição no início do período de maior venda (maior sazonalidade), devido ao grande volume de produtos manuseados dentro dos centros de distribuição e alto volume de faturamento (o que acarreta em menor tempo disponível para localizar o produto mais antigo dentro do estoque).

Os resultados projetados do envelhecimento do inventário de produtos acabados para os meses de junho a dezembro utilizando as previsões e premissas acima são apresentados na Tabela 7. O envelhecimento (Y) representa a projeção do quanto o inventário acima de 180 dias deverá aumentar ou diminuir a cada período.

PERÍODO	INVENTÁRIO <180 DIAS (C1)	VENDA (C2)	DEVOLUÇÕES (C3)	FIFO (C4)	ENVELHECIMENTO (Y)
jun/15	90.325	36.841	2.165	0,78	- 64
jul/15	92.022	36.946	4.747	0,82	- 979
ago/15	124.419	61.608	4.000	0,84	- 168
set/15	133.095	100.428	4.000	0,83	- 2.005
out/15	125.084	119.753	4.000	0,85	- 4.445
nov/15	99.957	132.520	4.000	0,84	- 6.618
dez/15	83.310	114.219	4.000	0,84	- 6.274

Tabela 7: Projeção do envelhecimento do inventário de produtos acabados através de regressão PLS em Minitab

Fonte: Dados da empresa

A projeção do estoque ao longo do tempo foi utilizada para priorizar as ações e alocar recursos de forma eficaz para redução do risco de obsolescência do inventário. Conhecendo o comportamento futuro de determinado grupo de itens a partir das variáveis observadas e da projeção dos resultados ao longo do tempo, foi possível definir ações precisas e específicas para cada tipo ou grupo de item.

A projeção do estoque ao longo do tempo proporcionou a definição do objetivo a ser alcançado pelo projeto com maior clareza. Conhecendo o comportamento futuro do estoque, tornou-se possível definir uma meta factível ao final do processo com base nas estimativas futuras, ou redefinir as ações de forma que determinado resultado fosse obtido ao final do processo.

#### **4.2.4. Definir o conjunto de diretrizes mais apropriadas para redução do inventário com risco de obsolescência ou deterioração**

##### **4.2.4.1. Revisar o objetivo e definir a linha de base**

De posse dos dados e informações detalhadas, e conhecendo o conjunto de variáveis com maior impacto sobre o envelhecimento e risco de obsolescência do inventário, o time multifuncional em conjunto com a Diretoria da empresa revisaram o objetivo principal do projeto a ser atendido até 31 de dezembro de 2015, além de definirem novos objetivos secundários.

Considerando que o objetivo principal da implantação do método na empresa objeto do Estudo de Caso 1 é a redução do inventário com idade superior a 180 dias até 31 de dezembro de 2015, a projeção do envelhecimento do inventário ao longo do tempo auxiliou na definição do objetivo principal a ser alcançado até 31 de dezembro de 2015, o qual foi definido pelos gestores da empresa como a redução do inventário acima de 180 dias em 70%, de forma a proteger o resultado contábil da empresa através da redução da provisão para perda e obsolescência a que está sujeito o inventário com idade superior a 180 dias. Reduzindo em 70% o montante de inventário acima de 180 dias até 31 de dezembro de 2015, o resultado líquido da empresa não

correria o risco de chegar a patamares negativos, e a projeção inicial realizada em maio de 2015 mostrou que este objetivo é possível de ser alcançado.

Além do objetivo principal, foram definidos objetivos secundários para o período de maio a dezembro de 2015: (i) atingir uma performance mínima do FIFO de 0,84, e; (ii) reduzir o inventário com idade inferior a 180 dias em no mínimo 20% (para reduzir o risco deste inventário migrar para a faixa com idade superior a 180 dias).

O ponto de partida para medir a performance das ações e definir a base para futuras previsões e monitoramento foi a posição do inventário contábil da empresa em 30 de abril de 2015, mês de início dos trabalhos do time multifuncional, definido como linha de base do projeto.

#### 4.2.4.2. Definir o plano de ação consolidado e o calendário de reuniões periódicas

O time multifuncional definiu ações para todas as áreas envolvidas no problema; tais ações seriam implantadas e monitoradas sob a responsabilidade das respectivas áreas e com o acompanhamento do time multifuncional. As ações definidas foram reunidas em um único plano de ação, acompanhado mensalmente nas reuniões periódicas de acompanhamento do projeto. O comparativo entre o previsto e o realizado de cada uma das ações incluída no plano de ação consolidado era pauta das reuniões de trabalho do grupo multifuncional (reuniões do grupo de trabalho multifuncional, reuniões de comunicação interna e reuniões de comunicação externa). Cada área tornou-se responsável pela coleta e acompanhamento periódico dos dados, análise dos resultados e da causa raiz das variações, quando necessário.

Dentre as ações implantadas, destacam-se a alteração da lógica do sistema WMS para que a data de produção do item seja utilizada para fins de operação do FIFO, a estruturação de um processo e política de vendas diferenciada para produtos descontinuados ou descasados para mercados e clientes específicos (por exemplo, lojas especializadas em produtos salvados), a definição de um processo contínuo de retrabalho de produtos devolvidos ou danificados buscando a redução constante desta parcela de inventário, e a alteração do processo de devolução de produtos com a introdução de um sistema de alçadas de aprovação com vistas a redução do volume de devoluções.

Um calendário de reuniões com datas fixas foi definido no início do projeto. As reuniões foram divididas em três grupos com periodicidades distintas, sendo: (i) reuniões do grupo de trabalho multifuncional, realizadas semanalmente, com a participação esporádica de convidados das áreas envolvidas (especialistas nas áreas ou funcionários diretamente envolvidos no processo); (ii) reuniões de comunicação interna, realizadas mensalmente para divulgar os resultados



obtidos à alta gestão da empresa no Brasil, e; (iii) reuniões de comunicação externa, para divulgar os resultados obtidos à controladora no exterior e/ou ao conselho diretor.

#### **4.2.5. Gestão da redução do risco de obsolescência ou deterioração do inventário**

##### 4.2.5.1. Coletar dados atualizados

As quatro primeiras etapas do método foram fundamentais para construção da base necessária de dados, conhecimentos e alinhamento de expectativas entre o time multifuncional e a gestão da empresa, de forma a garantir que a etapa cinco pudesse ser aplicada com sucesso.

O time multifuncional foi responsável por providenciar, mensalmente, a coleta de dados de estoque e das variáveis selecionadas, em um ciclo contínuo mensal. Para garantir a acurácia das informações, as fontes e os métodos para obtenção dos dados foram padronizados, através da criação de relatórios específicos no ERP da empresa e utilização de dados oficiais da área de Contabilidade (dados utilizados para construção das demonstrações financeiras da empresa).

##### 4.2.5.2. Projetar o estoque

O time multifuncional foi responsável por projetar, mensalmente, o valor do estoque ao longo do tempo para cada faixa de idade, incluindo as coletas de dados mais recentes, em um ciclo contínuo mensal. A projeção do estoque foi realizada, inicialmente, com suporte do software Excel e, posteriormente, analisados com suporte do software Minitab através da regressão PLS e da função “*Best Subset*”.

A projeção do estoque ao longo do tempo contribuiu para que os gestores da empresa e o time multifuncional pudessem prever o impacto futuro das ações definidas, avaliar a necessidade de implantar novas ações e focar sobre determinado processo ou variável para alavancar os resultados. A estimativa dos valores futuros foi fundamental para alinhar a expectativa de resultado financeiro da empresa ao final do exercício contábil com o esforço necessário do time multifuncional diretamente envolvido no projeto de redução do inventário com idade acima de 180 dias. Além disso, a previsão do envelhecimento do estoque mostrou-se fundamental para elaboração de estratégias e manutenção do controle, conduzindo a empresa a um resultado favorável.

##### 4.2.5.3. Atualizar resultados e avaliar eficácia das ações

A metodologia do Ciclo PDCA foi utilizada para, mensalmente, coletar dados, avaliar resultados, verificar a eficácia e definir novas ações, com objetivo de prover a melhoria contínua dos resultados. Para tal, a primeira reunião do grupo de trabalho multifuncional de cada mês

era dedicada à análise dos dados coletados e verificação da eficácia das ações no mês anterior. A segunda reunião do grupo de trabalho multifuncional de cada mês tinha como agenda a projeção do estoque ao longo do tempo e avaliação do risco de obsolescência do estoque para cada grupo de item e/ou faixa de idade. Na terceira reunião do grupo de trabalho multifuncional de cada mês novas ações eram definidas ou correções nas ações existentes eram recomendadas, de forma a garantir o bom resultado do projeto. Já a quarta reunião do grupo de trabalho multifuncional de cada mês era destinada a preparação da apresentação das reuniões de comunicação interna e externa, realizadas ao final de cada mês.

#### 4.2.5.4. Padronizar e revisar ações corretivas

As melhorias implementadas que conduziram a uma redução do risco de obsolescência do inventário foram padronizadas e implantadas nas rotinas de trabalho das empresas. Sempre que possível, estas melhorias foram incluídas no sistema ERP, ou então inseridas em normas e procedimentos existentes ou criados para este propósito específico.

#### 4.2.5.5. Rever objetivos e estabelecer novas metas

Após a revisão dos resultados e projeção do estoque, as ações previamente definidas foram revisadas mensalmente e alteradas sempre que necessário, de forma a garantir o atingimento dos resultados. Adicionalmente, novas ações foram definidas sempre que necessário para corrigir o andamento do processo, e ações que não trouxeram os resultados esperados foram canceladas.

A quinta etapa do método, que propõe a aplicação sistêmica de um método gerencial de acompanhamento dos resultados e atingimento das metas com base nos princípios do Ciclo PDCA, mostrou-se muito eficaz para o atingimento dos resultados propostos. A metodologia permite uma análise eficiente dos resultados (previsto vs. realizado), e a atualização da estimativa dos resultados futuros com base nos últimos resultados obtidos e nas previsões mais atuais da área Financeira da empresa. A avaliação dos resultados obtidos, em conjunto com a atualização da visão futura, permite aos gestores da empresa e ao time multifuncional a leitura do cenário atual de forma muito objetiva e clara. Este conjunto de informações proporciona aos gestores e ao time multifuncional uma visão clara da necessidade de alteração das ações já implantadas, cancelamento de ações que não surtiram o efeito necessário ou mesmo a implantação de novas ações para que o objetivo futuro seja alcançado. Proporciona, ainda, uma visão futura atualizada, proporcionando à área Financeira da empresa a oportunidade de

antecipar riscos ou oportunidades referentes ao fechamento contábil do exercício com maior antecedência.

Os resultados obtidos nesta fase do processo mostram que a escolha das variáveis e a regressão PLS apresentaram cenários de envelhecimento futuro do inventário com um nível de precisão adequado para tomada de decisão. Os valores reais das variáveis apurados ao final de cada período foram atualizados e inseridos na base de dados para estimativa dos valores futuros. De tal forma, a cada fechamento de mês, o valor realizado das variáveis selecionadas foi adicionado à base de dados existente desde setembro de 2014, e uma nova equação para previsão (estimativa) do inventário futuro da empresa foi gerada. O APÊNDICE 1 traz os dados previstos e realizados de junho a novembro de 2015 para cada uma das variáveis selecionadas. A Tabela 8 apresenta os novos coeficientes de regressão gerados com suporte do software Minitab, a cada nova rodada mensal de previsão, utilizando a base de dados expandida a cada mês (APÊNDICE 1).

COEFICIENTES DE REGRESSÃO	PERÍODO DA PREVISÃO							
	mai	jun	jul	ago	set	out	nov	
Interseção	22.050	21.428	21.911	25.023	24.092	27.136	25.200	
INVENTÁRIO <180 DIAS (C1)	0,058	0,064	0,069	0,061	0,060	0,065	0,055	
VENDA (C2)	- 0,069	- 0,072	- 0,074	- 0,077	- 0,075	- 0,084	- 0,078	
DEVOLUÇÕES (C3)	0,893	0,776	0,670	0,742	0,743	0,736	0,760	
FIFO (C4)	- 34.365	- 33.286	- 34.231	- 37.523	- 36.412	- 40.281	- 37.124	

Tabela 8: Coeficientes de regressão gerados mensalmente de junho a novembro de 2015 com base nos replanejamentos mensais

Fonte: Dados da empresa

A Tabela 9 traz os resultados finais do envelhecimento do inventário (Y) com base nas variáveis selecionadas (C1 a C4), no período de junho a novembro de 2015, utilizando a base de dados expandida a cada mês (APÊNDICE 1).

ENVELHECIMENTO (Y)	PERÍODO DA PREVISÃO							
	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15	dez/15
jun/15	- 64	485						
jul/15	979	1.652	2.097					
ago/15	- 168	104	78	713				
set/15	- 2.005	- 1.824	- 1.777	- 2.774	- 3.035			
out/15	- 4.445	- 4.151	- 4.183	- 4.603	- 3.853	- 3.161		
nov/15	- 6.618	- 6.704	- 6.894	- 7.164	- 6.753	- 7.345	- 7.008	
dez/15	- 6.274	- 6.390	- 6.502	- 6.963	- 6.525	- 6.700	- 5.992	- 6.154

PREVISTO REALIZADO

Tabela 9: Envelhecimento do inventário com base nos replanejamentos mensais realizados de junho a novembro de 2015

Fonte: Dados da empresa

O valor do envelhecimento, que representa a variação de um mês para o outro sobre o montante total do inventário acima de 180 dias, foi utilizado para calcular o valor total estimado para o

inventário acima de 180 dias de junho a dezembro de 2015. O valor do inventário acima de 180 dias em 31 de maio de 2015 serviu como linha de base para cálculo do valor estimado do inventário acima de 180 dias nos meses subsequentes. A Tabela 10 apresenta o valor final previsto (estimado) e realizado do inventário acima de 180 dias para os meses de junho a dezembro de 2015.

INVENTÁRIO >180 DIAS	PERÍODO DA PREVISÃO							
	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15	dez/15
mai/15	26.729	26.729	26.729	26.729	26.729	26.729	26.729	26.729
jun/15	26.665	27.214	27.214	27.214	27.214	27.214	27.214	27.214
jul/15	27.644	28.866	29.311	29.311	29.311	29.311	29.311	29.311
ago/15	27.476	28.969	29.389	30.024	30.024	30.024	30.024	30.024
set/15	25.471	27.145	27.613	27.250	26.989	26.989	26.989	26.989
out/15	21.025	22.995	23.430	22.648	23.136	23.828	23.828	23.828
nov/15	14.407	16.290	16.536	15.484	16.383	16.483	16.820	16.820
dez/15	8.132	9.900	10.034	8.521	9.858	9.784	10.828	10.666

  PREVISTO
   REALIZADO

Tabela 10: Valor total do inventário acima de 180 dias com base nos replanejamentos mensais realizados de junho a novembro de 2015

Fonte: Dados da empresa

A análise entre o valor previsto e o realizado para o inventário acima de 180 dias, utilizando o conceito de replanejamento mensal dos valores futuros com base no valor realizado no mês imediatamente anterior mostrou-se eficaz para estimar valores futuros do inventário com uma precisão adequada. Os resultados obtidos mostram que a variação entre o valor previsto e o realizado para o total do inventário com idade superior a 180 dias foi inferior a 3% para o mês subsequente ao da previsão (horizonte de 30 dias), e inferior a 10% para um horizonte de 90 dias a partir da data da previsão. Esta variação foi considerada adequada pelos gestores da empresa e pelo time multifuncional para estimativa dos resultados futuros com propósito de redução do inventário com idade superior a 180 dias até 31 de dezembro de 2015, principalmente considerando que as variáveis selecionadas para regressão apresentam variação mensal dependendo das condições do mercado, demandas de clientes, cenário econômico e processos internos complexos (gestão da produção e do FIFO de produtos acabados). A Tabela 11 traz a variação entre o valor previsto (estimado) e o realizado mensalmente para o valor total do inventário acima de 180 dias. Importante observar que a empresa não disponibilizou dados a partir de janeiro de 2016, restando a análise limitada aos dados disponíveis até 31 de dezembro de 2015.

PREVISTO vs. REALIZADO	PERÍODO DA PREVISÃO						
	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15
jun/15	-2,0%						
jul/15	-5,7%	-1,5%					
ago/15	-8,5%	-3,5%	-2,1%				
set/15		0,6%	2,3%	1,0%			
out/15			-1,7%	-5,0%	-2,9%		
nov/15				-7,9%	-2,6%	-2,0%	
dez/15					-7,6%	-8,3%	1,5%
jan/16						ND	ND
fev/16							ND
<b>30 DIAS</b>	<b>60 DIAS</b>		<b>90 DIAS</b>		<b>ND</b>	<b>DADO NÃO DISPONÍVEL</b>	

Tabela 11: Variação entre o previsto e o realizado mensalmente para o valor total do inventário acima de 180 dias

Fonte: Dados da empresa

Embora o objetivo principal definido pela empresa em maio de 2015 de reduzir o inventário acima de 180 dias em 70% até 31 de dezembro de 2015 não tenha sido atingido (a redução obtida foi de 60,1% sobre a linha de base de 31 de maio de 2015), há o consenso entre os gestores da empresa e o time multifuncional de que a implantação da metodologia foi fundamental para maximização dos resultados e para o aumento de precisão do planejamento financeiro da empresa, e que os resultados obtidos não seriam tão expressivos caso a metodologia não tivesse sido implantada. Além disso, os resultados obtidos com a implantação do método proposto de maio a dezembro de 2015 foram melhores do que os obtidos antes da implantação da metodologia, no período de novembro de 2014 (início do projeto de redução do inventário) a abril de 2015 (demanda das controladoras internacionais da empresa para que uma metodologia robusta fosse implantada para reduzir o inventário com idade superior a 180 dias até 31 de dezembro de 2015). A Figura 2 apresenta os resultados obtidos antes e após a implantação do método proposto neste trabalho.

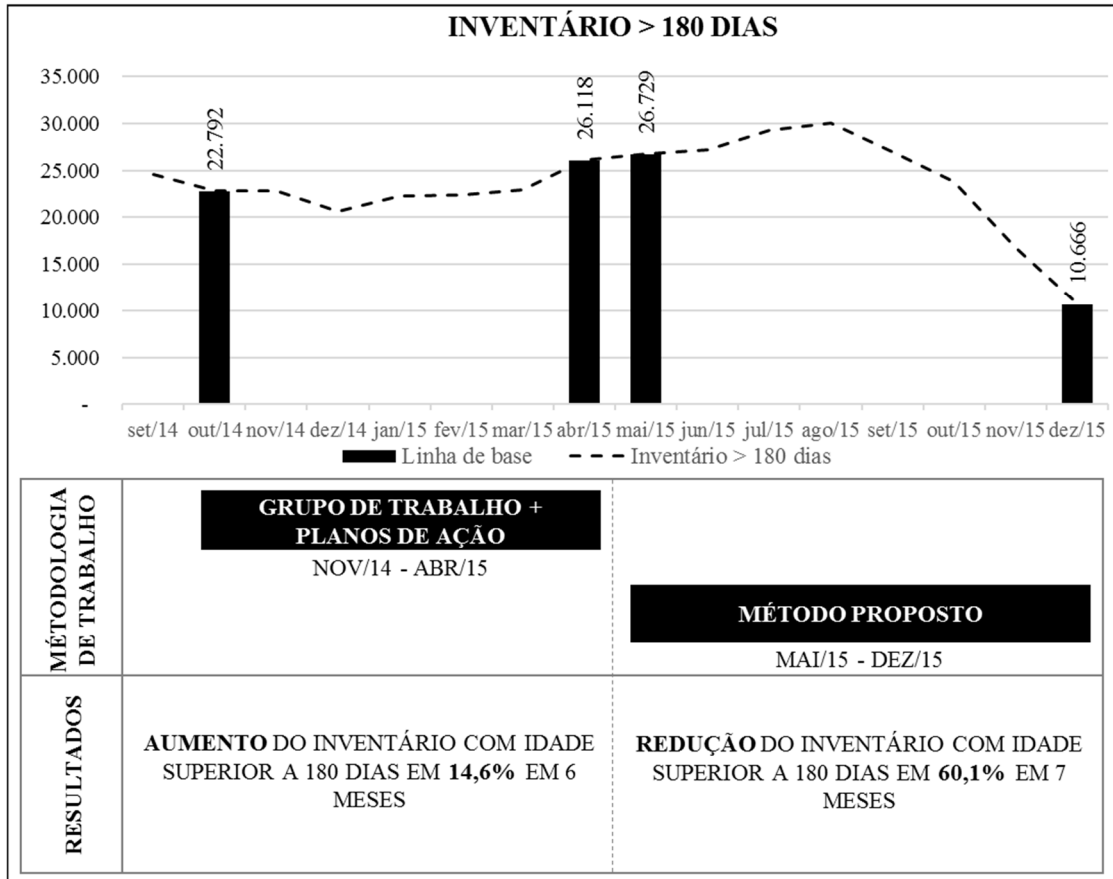


Figura 2: Resultados obtidos antes e depois da implantação do método proposto  
Fonte: Dados da empresa

Quanto aos objetivos secundários, ambos foram atingidos. A performance mínima do FIFO em dezembro de 2015 foi de 0,84, e a redução do inventário com idade inferior a 180 dias em 31 de dezembro de 2015 foi de 23,2%. Há consenso entre os gestores da empresa e o time multifuncional de que a implantação da metodologia foi fundamental para o atingimento dos objetivos secundários.

## 5. ESTUDO DE CASO 2

### 5.1. CARACTERIZAÇÃO DA EMPRESA

Uma indústria farmacêutica, parte de um grupo nacional formado por três empresas, iniciou uma série de projetos com vistas a obter vantagem competitiva de custo frente aos seus concorrentes. Os projetos visam à eliminação de desperdícios, redução de custos e redução de despesas.

A produção desta indústria é dividida em três tipos de produtos - medicamentos, cosméticos e alimentos – sendo a venda de produtos cosméticos, em especial os produzidos para terceiros (terceirização de fabricação), a principal fonte de renda da empresa. Uma parcela representativa dos produtos fabricados por esta indústria apresenta sazonalidade acentuada (por exemplo, protetores solares, cuja venda é concentrada nos meses que antecedem o verão), e a venda aos consumidores finais é realizada exclusivamente através do varejo, principalmente dos canais farmacêutico e alimentar.

A empresa produz um portfólio amplo e diversificado de produtos (principalmente por atuar fortemente na terceirização de produção), contando, atualmente, com mais de 350 produtos ativos e produzidos com regularidade. A diferenciação entre produtos similares fabricados para clientes distintos, seja por exigência ou especificação dos clientes, seja para garantir que os consumidores finais não tenham a percepção de que um mesmo produto é vendido sob diversas marcas diferentes, é fundamental para garantir a percepção e a experiência de uso da marca que cada cliente desta indústria pretende passar aos seus consumidores. Esta diferenciação é obtida através da utilização de ativos que garantem apelos específicos a cada produto (fragrâncias, óleos essenciais, sensorial de aplicação, cor, textura, viscosidade, entre outros), os quais estão ligados à identidade ou comunicação de marketing de cada uma das marcas. Com isso, a indústria precisa dispor em seu estoque de uma vasta quantidade de matérias primas diferentes, sendo que algumas são utilizadas em quantidades muito pequenas.

Como a demanda no varejo é afetada por fatores como clima, investimento em marketing e divulgação, promoções, ações de produtos concorrentes e disponibilidade de estoque, entre outros, a manutenção de um estoque regulador na indústria para evitar rupturas de abastecimento é um fator crítico de sucesso. Outro fator de extrema importância para o sucesso nas vendas no varejo, em especial para os produtos cosméticos, é o lançamento frequente de novos produtos, visto que os as inovações são muito valorizadas pelos consumidores. Sendo assim, os varejistas exigem investimentos constantes em divulgação, promoção e novos lançamentos. Neste cenário, o planejamento adequado da introdução de novos produtos, a

negociação de volumes mínimos de compra com os fabricantes de matérias primas e a gestão adequada dos estoques são processos chave para manutenção da competitividade da empresa.

Em sua busca pela eliminação de desperdícios, a empresa observou que um valor significativo de seu estoque é descartado mensalmente devido ao vencimento do prazo de validade de algumas matérias primas. Todas as matérias primas utilizadas na fabricação dos produtos são perecíveis, e seu prazo de validade varia de 6 meses a 3 anos. Além disso, quando a matéria prima entra na empresa geralmente não conta com o prazo total de validade, visto que já poderia estar no estoque do fabricante há alguns meses.

A eliminação deste desperdício trará uma melhoria significativa para o resultado financeiro da empresa, pois, dado tratar-se de produtos químicos, além do custo da baixa de estoque, há o custo do descarte de acordo com os requisitos legais, que deve ser efetuado por empresa qualificada e que disponha de homologação para tal pelos órgãos ambientais.

Além dos custos associados à baixa contábil das matérias primas, não há atualmente um processo capaz de prever o custo de descarte ao longo dos próximos meses, o que compromete a precisão do planejamento financeiro da empresa. Ainda mais importante, não há um processo capaz de identificar quais itens possuem maior risco de baixa por deterioração do inventário, ou mesmo identificar quais características de um determinado item influenciam em maior ou menor grau o risco de baixa de estoque por prazo de validade. Esta identificação prematura poderia auxiliar na definição de ações específicas para os itens com maior risco de deterioração.

A empresa decidiu, então, pela implantação de uma metodologia que a auxiliasse a projetar o custo da degradação do estoque ao longo dos meses, além de classificar os itens com maior risco de baixa por vencimento da validade de forma a definir ações precisas para eliminação ou mitigação do custo de degradação do inventário.

## 5.2. APLICAÇÃO DO MÉTODO

### 5.2.1. Investigar os fatores que contribuem para o aumento da idade do inventário

#### 5.2.1.1. Identificar o problema

Uma parcela significativa do estoque de matérias primas da empresa é descartada mensalmente devido ao vencimento do seu prazo de validade. Todas as matérias primas utilizadas na fabricação dos produtos são perecíveis, com prazo de validade que varia de 6 meses a 3 anos. No momento do recebimento das matérias primas na empresa, porém, estas não contam com o prazo total de validade, visto que, na maioria dos casos, já estavam há algum tempo no estoque dos fabricantes ou, no caso de matérias primas importadas, uma parcela do prazo de validade



foi consumido no transporte do país de origem até o Brasil. Para reduzir a exposição ao risco de deterioração do estoque, a indústria em questão só aceita o recebimento de matérias primas que dispõe de, no mínimo, 30% do prazo de validade nominal, procedimento formalizado com todos os fornecedores.

As matérias primas utilizadas em produtos farmacêuticos (medicamentos ou cosméticos) são, em sua maioria, importadas (adquiridas por importação direta ou através de distribuidores no Brasil). Estas matérias primas são vendidas em embalagens padrão, não fracionáveis, cujo tamanho de lote varia de aproximadamente 5 a 200 litros/quilos, dependendo da matéria prima. Embora na indústria em geral o ideal seja adquirir matérias primas em lotes cada vez menores e mais frequentes, na indústria farmacêutica os custos de análise química e microbiológica necessárias a cada lote adquirido (requisito legal) demandam uma análise mais profunda do custo benefício do tamanho de lote e da frequência de compra para minimizar os custos de análises. Acredita-se que o lote mínimo seja um fator relevante no risco de deterioração do inventário.

A necessidade de diferenciação entre produtos similares fabricados para diferentes marcas/clientes demanda a aquisição de ativos que garantem apelos específicos a cada produto. Estes ativos são geralmente utilizados em pequena quantidade na formulação dos produtos devido a necessidade de manter custos competitivos com o mercado. Os lotes mínimos de compra destes ativos, porém, são padronizados pela indústria, e geralmente não é possível realizar compra fracionada. Embora existam distribuidores que possuem licença da ANVISA para fracionamento de matérias primas, o custo de aquisição, nestes casos, costuma ser muito maior, comprometendo o custo dos produtos.

Embora existam matérias primas padronizadas e fabricadas por mais de uma indústria (álcool, glicerina líquida, silicones, etc.), uma parcela representativa das matérias primas é exclusiva de um determinado fabricante. As matérias primas que garantem apelos de venda diferenciados aos produtos (fragrâncias, óleos essenciais, entre outros), são quase em sua totalidade exclusivas de um determinado fabricante, e algumas (especialmente fragrâncias) são desenvolvidas especialmente para determinado produto.

Não há uma relação clara entre determinado tipo de matéria prima e as baixas por deterioração do estoque realizadas mensalmente. Os especialistas da empresa não conseguiram detectar nenhuma relação direta entre tipos de item e baixas por deterioração, visto que outros fatores como tamanho de lote, lead time de compra e prazo de validade também estão relacionados ao risco de deterioração.

Os dados históricos da empresa mostram que não há despesa relevante com a baixa de produtos acabados por deterioração, visto que a empresa já mantém controle das datas de validade dos produtos em estoque e toma medidas comerciais (concessão de descontos, promoções, bonificação comercial) quando aproxima-se a data de vencimento de algum item. Logo, o maior risco de deterioração de estoques está ligado ao inventário de matérias primas.

O objetivo principal da implantação do método na empresa objeto do Estudo de Caso 2 é a redução das despesas com o descarte de matérias primas devido ao vencimento do seu prazo de validade. A definição do problema de forma clara e objetiva por parte da empresa foi fundamental para obter a redução das despesas com o descarte de matérias primas devido ao vencimento do seu prazo de validade.

#### 5.2.1.2. Organizar o time multifuncional

A organização do time multifuncional ficou a cargo da Gerência da empresa. O time multifuncional foi formado por seis pessoas das áreas de Controle da Qualidade, Gestão da Qualidade, Produção, PCP, P&D e Marketing. Como líder do projeto foi escolhida a Supervisora do Controle de Qualidade. Dada a natureza do problema, não foi necessária a participação de representantes de fornecedores. A responsabilidade de forçar a equipe enxergar outros pontos de vista e encontrar falhas na lógica fazendo perguntas persistentes ficou a cargo dos Coordenadores de cada uma das áreas envolvidas, os quais participavam juntamente com o time multifuncional das reuniões de trabalho.

A organização do time multifuncional com especialistas das áreas diretamente envolvidas no problema contribuiu para a identificação das regras e procedimentos aplicáveis a estoques obsoletos e para a objetividade das ações propostas.

#### 5.2.1.3. Identificar regras e procedimentos aplicáveis a estoques obsoletos ou deteriorados

As normas, procedimentos, políticas, questões regulatórias ou exigências de clientes aplicáveis a estoques obsoletos foram obtidas através de uma atividade de *brainstorming* e entrevistas com o time multifuncional e especialistas das áreas diretamente envolvidas no problema, para assegurar que nenhum requisito tenha ficado de fora do processo.

Todas as matérias primas recebidas na empresa recebem uma indicação de lote interno, controlada pelo sistema ERP, por exigência das normas da ANVISA. Este sistema auxilia o funcionamento do FIFO, visto que o controle dos lotes deve ser registrado nas ordens de

produção, e é validado pelas áreas de Controle de Qualidade e PCP, dificultando a utilização de um lote que não seja de fato o mais antigo.

O procedimento interno que estipula um prazo mínimo de 30% do prazo de validade nominal das matérias primas ao chegarem à empresa, acordado formalmente com os fornecedores, mostrou-se de grande relevância para a deterioração do inventário, principalmente para algumas matérias primas de menor prazo de validade (inferior a 2 anos).

As matérias primas deterioradas, por tratarem-se de produtos químicos, devem ser descartadas através de empresas que possuam homologação dos órgãos ambientais para garantir a correta destinação dos resíduos industriais. Este requisito aumenta consideravelmente o custo de descarte destes itens.

Embora a empresa monitore a validade das matérias primas em estoque e eventualmente opte pela fabricação de um lote de produtos acabados apenas para evitar o vencimento de determinada matéria prima, esta prática não tem se mostrado suficiente para eliminar o risco de deterioração do inventário.

#### 5.2.1.4. Identificar fatores que podem gerar estoque obsoleto ou deteriorado

A identificação dos fatores que podem gerar estoque obsoleto foi realizada através de uma atividade de *brainstorming* com o time multifuncional e especialistas da empresa. A análise da listagem de itens vencidos e descartados nos últimos meses não mostrou uma relação clara entre os itens deteriorados e possíveis causas.

A grande variedade de produtos acabados (mais de 350 produtos ativos), os quais utilizam ativos distintos para garantir apelos e sensoriais diferenciados por exigência do mercado e dos clientes, demandam a manutenção de uma vasta variedade de matérias primas em estoque. Considerando que o volume destes ativos em especial na formulação dos produtos é pequeno (em função de seu custo mais elevado), há um entendimento de que os ativos utilizados para garantir apelos e diferenciar produtos correm o risco de deterioração no inventário.

A necessidade de lançamentos constantes de novos produtos e inovações também exige o desenvolvimento, qualificação e aquisição de novas matérias primas com frequência. Porém, nem todos os novos produtos lançados atingem o volume de vendas esperado. O risco de deterioração das matérias primas dos produtos com performance de venda aquém do esperado é superior à das matérias primas utilizadas nos produtos com maior volume de produção. Por outro lado, a descontinuação de linhas de produto por solicitação de clientes ou por baixa performance de venda no varejo também aumenta o risco de deterioração das matérias primas.

Uma característica relevante da indústria farmacêutica é que o desenvolvimento dos produtos é feito, inicialmente, em laboratório, em um volume menor (em equipamentos de menor porte). Após os testes de validação exigidos pela ANVISA, um primeiro lote em escala industrial é fabricado na produção, com acompanhamento da área de P&D, em um evento denominado “transferência de tecnologia”. Neste momento, são realizados ajustes na fórmula do produto para obter um produto final de acordo com as especificações em um lote industrial, e é comum ocorrer a redução ou aumento da quantidade de algumas matérias primas na formulação do produto. Esta alteração é um fator de risco de deterioração das matérias primas que já foram compradas para fabricação do primeiro lote de produção.

A devolução de produtos que apresentam baixa performance no varejo também está presente no varejo farmacêutico e no varejo alimentar. As grandes redes varejistas preveem em contrato cláusulas sobre a devolução de produtos com performance de venda abaixo do esperado, além de condicionar a colocação de novos pedidos à devolução de produtos com baixo giro de estoque.

## **5.2.2. Classificar o estoque em faixas de idade para mensurar o risco de obsolescência ou deterioração do inventário**

### **5.2.2.1. Coletar dados**

Após o estudo inicial, foram definidos os dados a serem coletados mensalmente para garantir as informações necessárias ao time multifuncional. Os dados foram obtidos diretamente do sistema ERP da empresa, dos relatórios da área Financeira e de controles da área de Produção. Foram definidos responsáveis dentro do time multifuncional por coletar os dados mensalmente e disponibilizar em um diretório de uso comum do projeto. Os dados coletados do sistema ERP estão listados no Quadro 11.

DADO	DEFINIÇÃO	OBJETIVO PRELIMINAR
Venda do período	Venda apurada em cada um dos períodos (meses), aberta por itens, em Reais (R\$) sem impostos	Avaliar a relação entre o volume de vendas e a deterioração do inventário de matérias primas
CPV do período (Custo do Produto Vendido)	Custo dos produtos vendidos em cada um dos períodos, em Reais (R\$) Inclui custos de matéria prima e materiais de embalagem, custo de mão de obra direta e custos diretos/indiretos de fabricação aplicados nos produtos vendidos no período	Avaliar a relação entre o CPV e a deterioração do inventário de matérias primas
Compras de materias primas do período	Volume de compra de matérias primas no periodo, em Reais (R\$)	Avaliar a relação entre o volume de compras de matérias primas e a deterioração do inventário de matérias primas
Inventário de matérias primas do período	Total de inventário de matérias primas ao final de cada um dos períodos (meses), em Reais (R\$)	Avaliar a relação entre o inventário de matérias primas e a deterioração das matérias primas
Inventário de produtos acabados do período	Total de inventário de produtos acabados ao final de cada um dos períodos (meses), em Reais (R\$)	Avaliar a relação entre o inventário de produtos acabados e a deterioração das matérias primas
Consumo de matérias primas do período	Consumo de matérias primas realizado em cada um dos períodos, em Reais (R\$)	Avaliar a relação entre o consumo de matérias primas na produção e a deterioração das matérias primas
Produtos prontos do período	Custo dos produtos fabricados em cada um dos períodos, em Reais (R\$) Inclui custos de matéria prima e materiais de embalagem, custo de mão de obra direta e custos diretos/indiretos de fabricação aplicados nos produtos fabricados no período	Avaliar a relação entre o custo dos produtos fabricados e a deterioração do inventário de matérias primas
Volume de produção do período	Produção realizada em cada um dos períodos (meses) em horas-padrão de produção (HH – Horas Homem)	Avaliar a relação entre o volume de produção e a deterioração do inventário de matérias primas
Acuracidade do forecast (previsão de vendas) do período	Acuracidade da previsão de vendas utilizada para planejamento de produção e materiais, item a item, em comparação a venda efetiva de cada mês	Avaliar a relação entre a acuracidade da previsão de vendas e a deterioração das matérias primas
Descarte de matérias primas deterioradas do período	Descarte de matérias primas por deterioração realizado em cada um dos períodos, em Reais (R\$)	Avaliar o impacto do descasamento de produtos no planejamento de produção e na produção no envelhecimento do inventário

Quadro 11: Dados coletados pelo time multifuncional a cada período (mensal)

Fonte: Dados da empresa

A coleta de dados foi realizada pelo time multifuncional e especialistas das áreas envolvidas na aplicação do método proposto, utilizando-se do conhecimento prévio dos participantes das rotinas e variáveis que compõem o processo de gestão de inventário. Considerando a baixa acuracidade dos dados anteriores a 2016, os dados utilizados no estudo foram coletados a partir de maio de 2016, período a partir do qual a empresa passou a tratar com maior relevância os custos relacionados à deterioração do inventário. Por solicitação da empresa, a unidade monetária dos dados não será divulgada devido a confidencialidade das informações.

#### 5.2.2.2. Classificar o estoque por tipo de item

A classificação dos itens em categorias é necessária para interpretação mais precisa dos dados e definição de métodos mais adequados de gestão para cada categoria. O sistema ERP da empresa possui apenas quatro categorias para os itens produtivos, sendo estas (i) produtos acabados (classificados como PA, são os produtos fabricados e disponíveis para venda); (ii) produtos intermediários (classificados como PI, são produtos cujo processamento foi iniciado porém não concluído, e ainda aguardam uma etapa de produção para tornarem-se disponíveis para venda); (iii) materiais de embalagem (classificados como ME, são as embalagens primárias e secundárias utilizadas nos produtos, além de rótulos, bulas ou outros itens utilizados para

acondicionamento dos produtos acabados), e; (iv) matérias primas (MP - ativos e insumos químicos ou orgânicos utilizados na fabricação dos produtos).

O sistema ERP da empresa não traz qualquer classificação para as diferentes matérias primas quanto à sua função (emolientes, ácidos, silicones, ervas, etc.), tipo (líquidos, sólidos, pastas, etc.) ou origem (química, orgânica, etc.). Além disso, os especialistas da empresa não veem a necessidade deste tipo de classificação, visto que há uma variedade muito grande de matérias primas, e seu uso ou função em determinado produto depende mais do tipo de produto que está sendo fabricado do que da matéria prima em si (por exemplo, o álcool pode ser utilizado como ativo em determinado produto, e como veículo em outro).

Como não há uma classificação clara das matérias primas que possa ser utilizada para estudar o comportamento de cada um dos grupos e sua relação com a deterioração do inventário, a relação entre as diversas matérias primas e o risco de deterioração foi realizado com o auxílio da análise discriminante.

Como ponto de partida, foi gerada uma listagem de matérias primas ativas no sistema ERP da empresa em janeiro de 2016. Para estes itens, foram obtidos no sistema ERP da empresa os dados de parametrização do módulo de MRP, os quais, segundo os especialistas da área de Produção, são utilizados para o planejamento de compras de materiais, com o propósito de estudar seu comportamento e relação com a deterioração do inventário. Como os especialistas da empresa não perceberam nenhuma tendência ou relação clara entre o tipo de matéria prima e o risco de deterioração, o time multifuncional classificou as matérias primas em três grupos distintos quanto à sua utilização nas fórmulas e volume de consumo, sendo: (i) Matéria prima de uso geral (compõe o chassi básico das fórmulas e são utilizadas em maior volume); (ii) Aditivos (matérias primas específicas, usadas para proporcionar determinado apelo ao produto, utilizadas em maior ou menor volume de acordo com o efeito desejado nos produtos), e; (iii) Essências (matérias primas para proporcionar aroma, exclusivas de um fabricante único, e utilizadas em pequenos volumes). Os parâmetros obtidos no sistema ERP e a classificação realizada pelos especialistas da área de P&D da empresa estão expostos no Quadro 12.

PARÂMETRO	DEFINIÇÃO	OBJETIVO PRELIMINAR
Lead time	O <i>lead time</i> (tempo de espera ou tempo de ciclo) da data de colocação do pedido de compras até a data de saída da matéria prima do fornecedor, em dias	Avaliar a relação entre o <i>lead time</i> de compra das matérias primas e a deterioração do inventário
Lote econômico de compra	Valor do lote econômico de compra calculado automaticamente pelo sistema ERP da empresa, utilizado para definição do tamanho de lote de compra mais vantajoso para a empresa, em unidades	Avaliar a relação entre o lote econômico de compra das matérias primas e a deterioração do inventário
Lote mínimo de compra	Valor do lote mínimo de compra definido pelo fornecedor, em unidades	Avaliar a relação entre o lote mínimo de compra das matérias primas e a deterioração do inventário
Tipo de planejamento	Parâmetro que define se o planejamento de compra do item será realizado através do MRP ou através de compra manual (parâmetro binário do sistema, utilizado para definir os itens que serão calculados pelo módulo MRP)	Avaliar a relação entre o tipo de compra (manual ou via MRP) das matérias primas e a deterioração do inventário
Status do item	Parâmetro que define se o item está ativo ou não (parâmetro binário do sistema, utilizado para segregar os itens ativos dos itens descontinuados)	Avaliar a relação entre o status do item e a deterioração do inventário

Quadro 12: Parâmetros do módulo MRP e classificação obtidos pelo time multifuncional  
Fonte: Dados da empresa

Além dos parâmetros do módulo MRP, uma informação considerada relevante pelos especialistas da área de Produção para o estudo da deterioração do inventário de matérias primas é o volume de compras mensal de matérias primas da empresa, em Reais (R\$). O volume de compras mensal é resultado da previsão de produção inserida no sistema e dos cálculos do módulo de MRP considerando os parâmetros de planejamento de compras.

Embora a informação do volume de compras mensal de matérias primas possa ser obtida no sistema ERP da empresa, é importante considerar que, devido aos processos e requisitos legais inerentes às indústrias farmacêuticas em geral, a empresa em questão tem como prática adotar, além do *lead time* do fornecedor, um prazo adicional de 60 dias para absorver os tempos de transporte e de análises laboratoriais (inspeção de recebimento). O tempo de transporte varia de 5 dias úteis (fornecedores locais com matéria prima disponível em estoque) a 45 dias (importação). Já as análises laboratoriais consomem de 3 dias (inspeções e análises químicas realizadas em laboratório interno) a 30 dias (ativos que demandam análises laboratoriais complexas realizadas em laboratório externo). Dadas estas particularidades, o planejamento de compras é feito de forma que as matérias primas cheguem ao recebimento de materiais da empresa 60 dias antes da data prevista para o seu consumo na produção de produtos acabados.

A aplicação da análise discriminante teve como objetivo a classificação do universo de matérias primas da empresa em grupos que representem o risco de deterioração de determinada matéria prima, através da aplicação de uma regra matemática que sirva para classificação de uma nova matéria prima em um dos grupos previamente estabelecidos. Tendo o conhecimento do menor ou maior risco de deterioração de uma matéria prima recém desenvolvida, pode-se tomar pedidas preventivas para eliminação ou mitigação do risco de deterioração.

Dada a dificuldade de classificação das matérias primas em diferentes tipos, a classificação sugerida pelos especialistas da área de Produção considerou os dados históricos de descarte de matérias primas por deterioração, objetivando a separação em dois conjuntos distintos de objetos ou observações da população observada, sendo: (i) grupo de matérias primas que não possuem histórico anterior de descarte por deterioração, e; (ii) grupo de matérias primas que possui histórico anterior de descarte por deterioração. Este agrupamento binário representa a variável dependente não métrica da análise.

A função de classificação para prever a adesão ao grupo utilizou as variáveis apresentadas no Quadro 11, além do volume de compras mensal de matérias primas da empresa com uma defasagem de 60 dias em função da premissa de antecedência adotada pela empresa, resultando no conjunto de variáveis para aplicação da análise discriminante exposto no Quadro 13.

VARIÁVEIS INDEPENDENTES	VARIÁVEL DEPENDENTE
X1 <i>Lead time</i>	<b>Y</b> Risco de descarte por deterioração Grupo 0: Não apresenta histórico de deterioração anterior Grupo 1: Apresenta histórico de deterioração anterior
X2 Lote econômico de compra	
X3 Lote mínimo de compra	
X4 Consumo anual	
X5 Tipo de planejamento	
X6 Volume de compra anual	
X7 Status do item	
X8 Tipo de item	

Quadro 13: Conjunto de variáveis utilizada para aplicação da análise discriminante  
 Fonte: Dados da empresa

A derivação da função discriminante foi realizada com suporte do software Minitab, e os resultados obtidos com as variáveis do Quadro 13 e os dados históricos da empresa referentes ao período compreendido entre maio de 2016 e abril de 2017 estão apresentados no Quadro 14.

Grupos			Sumário de classificações		
Grupo	0	1	Alocado no Grupo	Grupo Verdadeiro	
				0	1
Contagem	935	119	0	745	54
			1	190	65
Total de N				935	119
N correto				745	65
Proporção				0,797	0,546
Classificações corretas					
N	Correto	Proporção			
1054	810	0,769			
Distância Quadrática entre grupos					
	0	1			
0	0,000000	0,573515			
1	0,573515	0,000000			

Quadro 14: Resultados da análise discriminante com as variáveis do Quadro 13.

Fonte: Dados da empresa



A função discriminante resultado da análise, com vistas a classificação dos novos elementos (novas matérias primas) em um dos dois grupos é apresentada na Tabela 12.

<b>Grupos</b>	<b>0</b>	<b>1</b>
Constante	-19,384	-17,397
Lead time	0,049	0,051
Lote econômico de compra	0,000	0,000
Lote mínimo de compra	0,000	0,000
Consumo anual	0,000	0,000
Tipo de planejamento	4,416	5,172
Volume de compra anual	0,000	0,000
Status do item	34,089	30,948
Tipo de item	1,892	2,292

Tabela 12: Função discriminante linear com as variáveis do Quadro 13.

Fonte: Dados da empresa

As novas matérias primas cadastradas no sistema ERP da empresa a partir de maio de 2017 foram classificadas através da função discriminante linear, com vistas à predição dos grupos à qual pertencem. Foram cadastradas no sistema ERP da empresa 64 novas matérias primas após maio de 2017, e a classificação destas novas matérias primas através da função discriminante linear gerou as classificações apresentadas na Tabela 13.

<b>Grupo</b>	<b>0</b>	<b>1</b>
Contagem	11	53

Tabela 13: Classificação das matérias primas cadastradas após maio de 2017

Fonte: Dados da empresa

Importante observar que a maior parte das matérias primas cadastradas após maio de 2017 possuem Tipo de Item (ii – Aditivos, 40,6%) e (iii – Essências, 42,2%), ou seja, são em sua maioria matérias primas específicas, usadas para proporcionar determinado apelo ou aroma ao produto, o que pode explicar a maior concentração de itens no Grupo 1 (apresentam risco de deterioração).

Os novos itens classificados no Grupo 1, ou seja, que apresentam risco de deterioração, foram analisados individualmente pelas áreas de PCP e Compras, e encaminhados para renegociação dos parâmetros de compra, com vistas a reduzir o risco de deterioração dos mesmos.

Dos cinquenta e três itens classificados no Grupo 1, quatro tiveram baixa por descarte até outubro de 2017. Nenhum dos itens classificados no Grupo 0 tiveram baixa por descarte no período. Os novos itens que apresentaram baixa por descarte no período estão listados na Tabela 14.

CÓDIGO	DESCRIÇÃO	GRUPO (PREDITO)	LEAD TIME (X1)	LOTE ECON. (X2)	LOTE MÍN. (X3)	CONSUMO (X4)	TIPO PLANEJ. (X5)	VOL. COMPRA (X6)	STATUS (X7)	TIPO (X8)	DESCARTE (Y)
MP2710	ESS CHERRY FIG SCE324605	1	30	5.000	1.000	6.310	1	365	1	2	800
MP2711	ESS VERBENA 2 SCE323555	1	30	5.000	1.000	8.760	1	413	1	2	2.100
MP2718	OLEO DE MENTA	1	60	0	5.000	1.700	1	650	1	1	3.530
MP2724	ESS AVELA AR133384-0004	1	30	5.000	5.000	45.490	1	9.369	1	2	18.700

Tabela 14: Novos itens cadastrados no sistema ERP após maio de 2017 que apresentaram descarte por vencimento da data de validade

Fonte: Dados da empresa

A classificação dos itens conforme o risco de descarte futuro obtida através da análise discriminante mostrou-se muito adequada ao objetivo do trabalho, além de auxiliar na definição de ações e controles específicos sobre os novos itens cadastrados no sistema para mitigar o risco de descarte futuro. Ou seja, além de classificar os itens em função de seu risco de deterioração (em função das características específicas inerentes a cada item), a análise discriminante proporciona a possibilidade de indicar com antecedência novos itens com risco de deterioração futura e definir ações preventivas para redução deste risco.

#### 5.2.2.3. Classificar o estoque em faixas de idade

Diferentemente de outras indústrias (onde esta informação geralmente não está disponível), a idade de cada item do estoque é facilmente obtida no sistema ERP da empresa em função do requisito legal da ANVISA que demanda o controle do estoque por item, separado por lotes de matéria prima. Esta informação, obtida automaticamente através de relatórios de estoque do sistema ERP da empresa através do controle de lotes (em um formato que se mostrou adequado para as análises realizadas), foi utilizada para avaliar os diferentes lotes de matéria prima em estoque de um mesmo item, a idade de cada lote, o tempo restante para o vencimento da data de validade e a escolha do lote mais antigo para efeitos de FIFO. Ações específicas para cada item ou lote específico foram definidas em função da classificação do estoque por idade.

O conhecimento da idade do inventário é um pré-requisito para redução do risco de descarte por data de validade, visto que quanto menor a validade do item em estoque maior é o seu risco de deterioração. Como o estudo em questão limitou-se ao estoque de matérias primas, não houve a necessidade de exclusão de itens que não seriam abrangidos pelo projeto (estoque de manutenção ou de reposição).

### 5.2.3. Definir o conjunto de variáveis mais apropriado para projeção do inventário ao longo do tempo

#### 5.2.3.1. Estudar o processo e variáveis

O time multifuncional realizou uma análise preliminar do processo a partir dos dados coletados, de forma a definir quais características do processo possuíam maior relevância na deterioração

do inventário de matérias primas, estabelecer quais questões demandam maior profundidade de estudo e quais variáveis se mostram mais relevantes para o processo. O foco a análise foi o inventário de matérias primas, visto que representa 86% do custo total de descarte por deterioração do inventário empresa. Os instrumentos utilizados foram observação, análises de registros, arquivos e relatórios do sistema ERP (contemplando diferentes fontes de dados) e observação direta dos processos.

#### 5.2.3.2. Definir as variáveis

Após a análise do processo e suas variáveis, o conjunto de variáveis julgadas de maior relevância para a deterioração do inventário foi identificado pelo time multifuncional. Os dados utilizados representam o período compreendido entre maio de 2016 e abril de 2017, definido como o conjunto original de dados, e as variáveis selecionadas pelo time multifuncional estão apresentadas na Tabela 15.

ANÁLISE	FERRAMENTA	VARIÁVEIS	RESULTADO (R <sup>2</sup> )
1	Regressão múltipla	X1 = Venda do período X2 = CPV do período (Custo do Produto Vendido) X3 = Compras de materias primas do período X4 = Inventário de matérias primas do período X5 = Inventário de produtos acabados do período X6 = Consumo de matérias primas do período X7 = Produtos prontos do período X8 = Volume de produção do período X9 = Acuracidade do forecast (previsão de vendas) do período Y = Descarte de matérias primas deterioradas do período	0,9246

Tabela 15: Variáveis utilizadas para regressão linear múltipla da deterioração do inventário de matérias primas em Minitab

Fonte: Dados da empresa

O resultado da análise de regressão múltipla realizada através do software Minitab utilizando as variáveis apresentadas na Tabela 13 e os dados históricos do período compreendido entre maio de 2016 e abril de 2017 estão apresentados no Quadro 15.

Regressão MQP		Seleção de Modelo e Validação para Descarte		
Validação Cruzada	Nenhum	Componentes	Variância X	R2
Componentes para calcular.	Conjunto	1	0,195690	0,323686
Número de componentes calculados	9	2	0,376600	0,488717
		3	0,733600	0,535410
		4	0,788980	0,625760
		5	0,883720	0,672180
		6	0,906830	0,807065
		7	0,984010	0,809897
		8	0,990040	0,887659
		9	1,000000	0,924591
Sumário do Modelo				
S	R2	R2(aj)	R2(pred)	
3440,52	92,46%	58,52%	0,00%	

Quadro 15: Projeção da deterioração do estoque de matérias primas através de regressão múltipla em Minitab

Fonte: Dados da empresa

A análise preliminar das variáveis através da regressão linear múltipla auxiliou o time multifuncional a entender a relação das variáveis selecionadas empiricamente com o problema em. Embora o coeficiente de determinação  $R^2$  obtido através da regressão múltipla em Minitab tenha se mostrado satisfatório (0,9246), o valor do coeficiente  $R^2$  ajustado (0,5852) apresentou diferença relevante, indicando a inclusão indiscriminada de variáveis. Como o melhor ajuste está relacionado apenas a um subconjunto das variáveis independentes utilizadas, faz-se necessário definir um novo modelo através de técnicas de seleção de variáveis.

#### 5.2.3.3. Selecionar as variáveis mais relevantes para o propósito de predição

O valor do coeficiente  $R^2$  ajustado indicou a necessidade de reduzir o número de variáveis para obtenção de um modelo de previsão mais rápido, de menor complexidade e com melhores propriedades estatísticas, e que demande a coleta de um menor número de dados e a utilização de menor quantidade de recursos de processamento e armazenamento de informações.

A redução das variáveis foi obtida utilizando regressão PLS com o método BSS, utilizando o  $R^2$  ajustado e critério  $C_p$  de Mallows para redução das variáveis irrelevantes, ruidosas ou não confiáveis do modelo. O resultado desta análise é apresentado no Quadro 16.

						V e n d a	C P V	C o m p r a s	I n v e n t o	I n v e n t o	C o n s u m o	P r o d u ç o	V o l u m e	A c u r e c i s ã o
Vars	R2	R2 (aj)	R2 (pred)	Cp de Mallows	S	X1	X2	X3	X4	X5	X6	X7	X8	X9
1	20,00	12,00	0,00	13,20	5011,6				X					
1	6,80	0,00	0,00	16,70	5409,8	X								
2	34,90	20,50	4,30	11,30	4764,2			X	X					
2	24,80	8,10	0,00	13,90	5120,9				X		X			
3	59,50	44,30	21,50	6,70	3987,2			X				X	X	
3	46,80	26,90	12,40	10,10	4568,3			X	X	X				
4	69,80	52,50	24,40	6,00	3683,1			X		X		X	X	
4	68,60	50,70	0,00	6,30	3752,0			X			X	X	X	
5	76,30	56,60	0,00	6,30	3518,4			X		X	X	X	X	
5	75,40	54,80	29,10	6,50	3590,8		X	X		X		X	X	
6	80,90	57,90	0,00	7,10	3464,8		X	X		X	X	X	X	
6	79,40	54,70	0,00	7,50	3597,5	X		X		X	X	X	X	
7	85,60	60,40	0,00	7,80	3363,7	X	X	X		X	X	X	X	
7	81,90	50,10	0,00	8,80	3772,0		X	X		X	X	X	X	X
8	90,70	65,70	0,00	8,50	3126,6	X	X	X	X	X	X	X	X	
8	87,70	55,00	0,00	9,30	3584,2	X	X	X	X	X		X	X	X
9	92,50	58,50	0,00	10,00	3440,5	X	X	X	X	X	X	X	X	X

Quadro 16: Resultados da análise através da função *Best Subset* em Minitab

Fonte: Dados da empresa

O Quadro 16 mostra que o melhor resultado é obtido através da utilização de oito variáveis (X1, X2, X3, X4, X5, X6, X7 e X8), com o melhor  $R^2$  ajustado (0,6570) e o menor CP de Mallows (8,50). Para este modelo, o Cp de Mallows (8,50) possui um valor próximo do número de variáveis independentes mais a variável dependente (9), indicando que o modelo apresenta pequenas variações para estimar os coeficientes verdadeiros de regressão e prever respostas futuras.

As variáveis selecionadas com o propósito de predição representam características importantes do processo e, pela experiência do time multifuncional e de especialistas da empresa, estão diretamente relacionadas com o objetivo do projeto. As variáveis X1 (venda do período), X3 (compras do período) e X8 (volume de produção do período, em horas-homem) representam o volume de operação da empresa e, embora diretamente relacionadas, um desequilíbrio entre o volume de matérias primas compradas, produtos produzidos e produtos vendidos pode

influenciar diretamente no descarte de matérias primas. As variáveis X2 (CPV do período), X4 (inventário de matérias primas do período) e X5 (Inventário de produtos acabados do período) representam características do negócio com capacidade para absorver, até determinado nível, variações no volume de operação da empresa (retratado pelas variáveis X1, X3 e X8). Da mesma forma, as variáveis X6 (consumo de matérias primas do período) e X7 (produtos prontos do período) representam características do planejamento produtivo que podem absorver, até determinado ponto, variações na variável X2 (em função da parcela da produção do período destinada para estoque ou para venda).

A redução do número de variáveis foi fundamental para otimização de recursos, manutenção do foco sobre as variáveis com maior impacto sobre o resultado, redução do tempo de coleta e análise de dados, direcionamento de ações e definição dos controles necessários sobre os processos e atividades que impactam diretamente nas variáveis selecionadas.

#### 5.2.3.4. Projetar o estoque ao longo do tempo

O modelo de previsão utilizado para desenvolver alertas precoces e direcionar ações apropriadas para evitar o envelhecimento do inventário e reduzir o risco de obsolescência foi obtido através da análise de regressão no Minitab através das variáveis escolhidas com a função “*Best Subset*”. As variáveis utilizadas para regressão PLS estão listadas no Quadro 17.

VARIÁVEIS
X1 = Venda do período
X2 = CPV do período (Custo do Produto Vendido)
X3 = Compras de materias primas do período
X4 = Inventário de matérias primas do período
X5 = Inventário de produtos acabados do período
X6 = Consumo de matérias primas do período
X7 = Produtos prontos do período
X8 = Volume de produção do período
Y = Descarte de matérias primas deterioradas do período

Quadro 17: Variáveis utilizadas para regressão PLS

Fonte: Dados da empresa

A equação de regressão obtida com as variáveis apresentadas no Quadro 17 e os dados históricos da empresa relativos ao período compreendido entre maio de 2016 e abril de 2017 está apresentada na equação (20).

$$Y = 16430 - 0,01632x_1 + 0,0499x_2 + 0,0131x_3 + 0,00755x_4 - 0,00477x_5 + 0,0226x_6 - 0,0598x_7 + 12,20x_8 \quad (20)$$

Para a projeção dos resultados futuros (a partir de maio de 2017), foram utilizadas as seguintes premissas para as variáveis selecionadas pelo método como de maior relevância para o propósito de predição:

- a) Venda do período (X1): Utilizado a última previsão (*forecast*) de vendas da empresa (em Reais);
- b) CPV do período (X2): Utilizado a última previsão (*forecast*) de resultados da empresa (em Reais), obtida na DRE orçada da área Financeira;
- c) Compras do período (X3): Utilizado a última previsão (*forecast*) de compras da empresa (em Reais), obtida na projeção realizada pela área de PCP nas reuniões de S&OP (*Sales and Operations Planning*);
- d) Inventário de matérias primas do período (X4): Utilizado a última previsão (*forecast*) de estoque da empresa (em Reais), obtida na projeção realizada pela área de PCP nas reuniões de S&OP;
- e) Inventário de produtos acabados do período (X5): Utilizado a última previsão (*forecast*) de estoque da empresa (em Reais), obtida na projeção realizada pela área de PCP nas reuniões de S&OP;
- f) Consumo de matérias primas do período (X6): Calculado através da última previsão (*forecast*) de resultados da empresa (em Reais), obtida na DRE orçada da área Financeira, e a média histórica dos últimos 12 meses da participação percentual do custo das matérias primas no CPV total do período;
- g) Produtos prontos do período (X7): Calculado através da última previsão (*forecast*) de resultados da empresa (em Reais), obtida na DRE orçada da área Financeira, e a média histórica dos últimos 12 meses da participação percentual do custo dos produtos prontos na venda do período;
- h) Volume de produção do período (X8): Utilizado a última previsão (*forecast*) de produção da empresa (em “horas homem”), obtida na projeção realizada pela área de PCP nas reuniões de S&OP.

A projeção do inventário foi realizada inicialmente para o período de maio a outubro de 2017. Após a apuração dos resultados oficiais dos meses de maio e junho de 2017, a projeção foi estendida para os meses de novembro e dezembro de 2017. Os resultados projetados de deterioração do inventário de matérias primas da empresa de maio a dezembro utilizando as previsões e premissas acima são apresentados na Tabela 16.

PERÍODO	VENDA (X1)	CPV (X2)	COMPRAS (X3)	INVENTÁRIO MP (X4)	INVENTÁRIO PA (X5)	CONSUMO MP (X6)	PRODUTOS PRONTOS (X7)	VOLUME PRODUÇÃO (X8)	DETERIORAÇÃO (Y)
mai/17	2.950.000	1.197.864	779.980	1.637.840	2.940.265	452.220	1.332.590	3.800	13.509
jun/17	3.350.000	1.397.718	885.740	1.859.920	3.338.945	533.596	1.540.839	3.800	7.500
jul/17	3.500.000	1.458.449	925.400	1.943.200	3.488.450	535.163	1.603.675	4.100	8.455
ago/17	3.600.000	1.482.234	951.840	1.998.720	3.588.120	503.489	1.570.608	4.100	9.562
set/17	3.700.000	1.398.612	1.017.500	2.183.000	3.687.790	448.601	1.557.657	3.800	1.407
out/17	5.500.000	2.179.858	1.932.150	3.520.000	5.498.900	704.144	2.088.410	4.300	4.589
nov/17	4.500.000	1.798.234	1.254.600	2.498.400	4.485.150	566.925	1.749.311	4.100	4.850
dez/17	2.400.000	1.035.620	652.320	1.403.821	2.399.657	339.576	870.895	1.800	14.192

Tabela 16: Projeção da deterioração do inventário de matérias primas através de regressão PLS em Minitab

Fonte: Dados da empresa

A projeção da deterioração do inventário ao longo do tempo foi utilizada para priorizar as ações e alocar recursos de forma eficaz para redução do risco de deterioração do inventário. Conhecendo o comportamento futuro da deterioração do estoque de matérias primas a partir das variáveis observadas através da projeção com regressão PLS, e conhecendo as matérias primas com maior probabilidade de deterioração através do agrupamento por análise discriminante, foi possível definir ações precisas e específicas para cada matéria prima em função da relevância de seu valor de estoque.

A projeção do risco de descarte de matérias primas ao longo do tempo contribuiu para que os gestores da empresa e o time multifuncional pudessem prever o impacto futuro das ações definidas, avaliar a necessidade de implantar novas ações e focar sobre determinado processo ou variável para alavancar os resultados. A estimativa dos valores futuros foi fundamental para definir de forma mais precisa o orçamento financeiro da empresa para o próximo exercício contábil.

#### 5.2.4. Definir o conjunto de diretrizes mais apropriadas para redução do inventário com risco de obsolescência ou deterioração

##### 5.2.4.1. Revisar o objetivo e definir a linha de base

De posse dos dados e informações detalhadas, e conhecendo o conjunto de variáveis com maior impacto sobre a deterioração do inventário e os itens com maior risco de deterioração, o time multifuncional reavaliou o objetivo do projeto a ser atendido ao longo de 2018.

Considerando que o objetivo principal da implantação do método na empresa objeto do Estudo de Caso 2 é a redução das despesas com o descarte de matérias primas devido ao vencimento do seu prazo de validade, a projeção dos descartes futuros de matérias primas mostrou que é possível obter uma redução de 25% nas despesas com descartes de matérias primas vencidas de janeiro a dezembro de 2018. Não foram elencadas ações específicas para 2017 visto que as variáveis com maior impacto na deterioração do inventário não são passíveis de alteração no



curto prazo, demandando ações estruturais e sistêmicas para alteração do perfil de descarte de matérias primas.

O ponto de partida para medir a performance das ações e definir a base para futuras previsões de impacto e monitoramento foi a posição do inventário contábil da empresa em 30 de junho de 2016, de forma a possuir um histórico de seis meses de coleta e projeção dos dados antes do início do exercício fiscal de 2018. As áreas diretamente envolvidas no problema receberam ações a serem implantadas e monitoradas sob sua responsabilidade, com o acompanhamento do time multifuncional. O objetivo principal da implantação do método foi definido como a redução de 25% nas despesas com descartes de matérias primas vencidas de janeiro a dezembro de 2018. Não foram definidos objetivos secundários para o projeto.

#### 5.2.4.2. Definir o plano de ação consolidado e o calendário das reuniões periódicas

As ações definidas foram reunidas em um único plano de ação, acompanhado mensalmente nas reuniões periódicas de “Produtos Vencidos” (nome dado à reunião mensal). O comparativo entre o previsto e o realizado de cada mês é pauta das reuniões mensais. As áreas de PCP e Controle de Qualidade nomeadas responsáveis pela coleta e acompanhamento periódico dos dados, análise dos resultados e da causa raiz das variações, quando necessário.

Dentre as ações implantadas, destacam-se a centralização de todas as compras de matérias primas via MRP, a eliminação do cálculo do lote econômico pelo sistema MRP para definição dos pedidos de compra de matérias primas (todas as compras passaram a ser realizadas pelo lote mínimo de compra), a negociação com todos os fornecedores matérias primas utilizada em pequenos volumes para redução dos tamanhos mínimos de lote, a diretriz para utilização prioritária de matérias primas existentes para fabricação de produtos de baixo volume, a definição do tamanho de lote de produção de produtos de edições limitadas (produtos fabricados uma única vez para aproveitar datas comemorativas, eventos ou ações de marketing) em função dos tamanhos de lote mínimo de compra das matérias primas e a busca de potenciais compradores para matérias primas compradas em excesso que possuam risco de deterioração.

Foi definida uma reunião mensal, na segunda semana de cada mês (após o fechamento contábil) para avaliar os resultados do mês anterior, projetar o risco de deterioração do inventário do mês corrente e dos seis meses subsequentes, avaliar os itens com maior valor de risco de baixa por prazo de validade no mês corrente e nos próximos três meses, definir ações específicas para

cada um dos itens, e avaliar novos itens cadastrados no sistema ERP e sua classificação quanto ao risco de deterioração futura.

As informações referentes aos itens com maior valor de risco de baixa por prazo de validade no mês corrente e nos próximos três meses são obtidas diretamente do sistema ERP da empresa, visto que, por exigência da ANVISA, as matérias primas devem ser controladas por lote dentro do sistema de inventário. A classificação por faixas de idade é fundamental para análise do risco de deterioração e determinação de medidas precisas para redução do risco de baixa de matérias primas por deterioração. Na empresa em questão, esta análise é feita em base mensal, extraindo do sistema as matérias primas com risco de vencimento da data de validade no mês corrente e nos três meses subsequentes.

Embora haja dados no sistema suficientes para avaliar as matérias primas com vencimento em qualquer momento futuro (além dos três meses avaliados nas reuniões de Produtos Vencidos), considerando que o sistema de planejamento de vendas e produção da empresa, baseado no método S&OP, é realizado em horizonte futuro de três meses além do mês corrente, as informações disponíveis de estoque, venda e compras de matérias primas estão disponíveis com maior acurácia para a projeção da deterioração futura do inventário para o horizonte de três meses. Embora haja um entendimento na empresa sobre a viabilidade da aplicação de um horizonte maior de projeção com base em dados históricos, optou-se por projetar um horizonte de 12 meses apenas para fins de planejamento anual e definição das ações macro. Para operação mensal do processo a gestão da empresa optou por projetar o risco de deterioração futura sempre em horizontes de três meses para garantir maior acurácia dos dados.

Além da discussão dos resultados e ações, a mesma reunião mensal de “Produtos Vencidos”, é utilizada para a comunicação dos resultados e das projeções futuras para todo o time de gestão da empresa.

#### **5.2.5. Gestão da redução do risco de obsolescência ou deterioração do inventário**

##### **5.2.5.1. Coletar dados atualizados**

A exemplo do Estudo de Caso 1, as quatro primeiras etapas do método foram fundamentais para construção da base necessária para garantir que a quinta etapa fosse aplicada com sucesso.

As áreas de PCP e Controle de Qualidade foram nomeadas responsáveis para providenciar, mensalmente, a coleta de dados de estoque e das variáveis selecionadas, em um ciclo contínuo mensal. Para garantir a acurácia das informações, as fontes e os métodos para obtenção dos dados foram padronizados.

#### 5.2.5.2. Projetar o estoque

A área de PCP é responsável por projetar, mensalmente, o risco de deterioração do estoque de matérias primas ao longo do tempo, em um ciclo contínuo mensal. A projeção do risco de deterioração é realizada com suporte do software Excel, utilizando-se do método de regressão PLS sobre as variáveis selecionadas e a equação obtida com suporte do software Minitab (equação 20).

#### 5.2.5.3. Atualizar resultados e avaliar eficácia das ações

A metodologia do Ciclo PDCA foi utilizada para, mensalmente, coletar dados, avaliar resultados, verificar a eficácia e definir novas ações, com objetivo de prover a melhoria contínua dos resultados. Para tal, na reunião periódica de “Produtos Vencidos” é realizada a avaliação do resultado do mês anterior, a projeção do risco de deterioração do inventário do mês corrente e dos seis meses subsequentes, a avaliação os itens com maior valor de risco de baixa por prazo de validade no mês corrente e nos próximos três meses, e a definição de ações específicas para cada um dos itens. Nesta mesma reunião, os novos itens cadastrados no sistema ERP que forem classificados no grupo 1 através da função discriminante linear apresentada na Tabela 8, tem seus parâmetros de planejamento de compra revisados e, se necessário, alterados, de forma a que o risco de degradação futura seja eliminado ou mitigado.

#### 5.2.5.4. Padronizar e revisar ações corretivas

As melhorias implementadas que conduziram a uma redução do risco de deterioração do inventário de matérias primas são padronizadas e implantadas nas rotinas de trabalho da empresa. Sempre que possível, estas melhorias são inseridas em normas e procedimentos existentes ou criados para este propósito específico.

#### 5.2.5.5. Rever objetivos e estabelecer novas metas

Com vistas a garantir o atingimento dos objetivos, após a revisão dos resultados e projeção do risco de deterioração, as ações previamente definidas são revisadas e, se necessário, alteradas. Novas ações podem ser definidas para corrigir o andamento do processo, bem como ações que não trouxeram os resultados esperados devem ser canceladas.

A aplicação da quinta etapa do método, que consiste na aplicação sistêmica de um método gerencial de acompanhamento dos resultados e atingimento das metas com base nos princípios do Ciclo PDCA, mostrou-se muito eficaz para o atingimento dos resultados propostos. A metodologia permite uma eficaz análise dos resultados, além da atualização da estimativa dos

resultados futuros com base nos últimos resultados obtidos e nas previsões mais atuais da área Financeira e de PCP da empresa. A avaliação dos resultados obtidos, em conjunto com a atualização da visão futura, permitiu aos gestores da empresa e ao time multifuncional a leitura do cenário atual de forma objetiva, indicando a necessidade de alteração ou cancelamento das ações já implantadas ou a necessidade de definição de novas ações para que o objetivo futuro fosse alcançado. Além disso, proporcionou uma visão futura atualizada e dinâmica, permitindo à área Financeira da empresa a antecipação de riscos e oportunidades com maior antecedência.

Os resultados obtidos nesta fase do processo mostram que a seleção de variáveis e a regressão PLS proporcionam cenários de descarte futuro do inventário com um nível de precisão adequado para tomada de decisão. Os valores reais das variáveis apurados ao final de cada período foram atualizados e inseridos na base de dados para estimativa dos valores futuros. O APÊNDICE 2 traz os dados previstos e realizados de maio a dezembro de 2017 para cada uma das variáveis selecionadas. A Tabela 17 apresenta os novos coeficientes de regressão gerados com suporte do software Minitab, a cada nova rodada mensal de previsão, utilizando a base de dados expandida a cada mês (APÊNDICE 2).

COEFICIENTES DE REGRESSÃO	PERÍODO DA PREVISÃO						
	abr	mai	jun	jul	ago	set	out
Interseção	16.430,0	16.430,3	16.463,3	21.639,2	22.369,4	19.590,2	20.184,5
VENDA (X1)	- 0,0163	- 0,0163	- 0,0154	- 0,0139	- 0,0128	- 0,0167	- 0,0155
CPV (X2)	0,0499	0,0499	0,0473	0,0428	0,0389	0,0494	0,0471
COMPRAS (X3)	0,0131	0,0131	0,0132	0,0130	0,0129	0,0132	0,0129
INVENTÁRIO MAT. PRIMA (X4)	0,0076	0,0075	0,0074	0,0046	0,0040	0,0058	0,0053
INVENTÁRIO PROD. ACAB. (X5)	- 0,0048	- 0,0048	- 0,0048	- 0,0052	- 0,0046	- 0,0045	- 0,0046
CONSUMO MAT. PRIMA (X6)	0,0023	0,0226	0,0230	0,0194	0,0219	0,0251	0,0249
PRODUTOS PRONTOS (X7)	- 0,0598	- 0,0598	- 0,0594	- 0,0522	- 0,0520	- 0,0587	- 0,0569
VOLUME PRODUÇÃO (X8)	12,2	12,2	12,2	10,5	10,1	11,5	11,0

Tabela 17: Coeficientes de regressão gerados mensalmente de abril a outubro de 2017 com base nos replanejamentos mensais

Fonte: Dados da empresa

A Tabela 18 apresenta os resultados finais do descarte de matérias primas deterioradas (Y) e as variáveis selecionadas (X1 a X8), no período de maio a outubro de 2017, utilizando a base de dados expandida a cada mês (APÊNDICE 2).

PERÍODO	VENDA (X1)	CPV (X2)	COMPRAS (X3)	INVENTÁRIO MP (X4)	INVENTÁRIO PA (X5)	CONSUMO MP (X6)	PRODUTOS PRONTOS (X7)	VOLUME PRODUÇÃO (X8)	DESCARTE REALIZADO
mai/17	2.771.052	1.131.459	1.240.991	1.723.176	4.312.047	347.722	1.304.300	3.812	12.813
jun/17	3.326.301	1.420.525	746.518	1.876.130	4.070.037	186.364	1.065.095	2.552	8.170
jul/17	3.495.034	1.373.734	787.591	2.173.563	3.941.459	463.139	1.383.376	4.027	8.602
ago/17	4.474.310	1.834.940	1.136.716	2.104.102	3.480.277	420.494	1.666.838	4.386	8.784
set/17	3.949.975	1.515.586	1.747.376	1.966.984	3.388.173	593.864	1.790.769	3.895	1.291
out/17	6.264.781	2.338.033	1.157.686	1.928.614	2.830.778	627.655	1.809.781	4.193	4.999

Tabela 18: Descarte de matérias primas deterioradas e as variáveis selecionadas de maio a outubro de 2017

Fonte: Dados da empresa

A análise entre o valor previsto e o realizado para o descarte de matérias primas, utilizando o conceito de replanejamento mensal dos valores futuros com base no valor realizado no mês imediatamente anterior, mostrou-se eficaz para estimar valores futuros do inventário com uma precisão adequada. Os resultados obtidos mostram que a variação entre o valor previsto e o realizado para o descarte de matérias primas foi inferior a 10% para o mês subsequente ao da previsão (horizonte de 30 dias), variação considerada aceitável pelos gestores da empresa e pelo time multifuncional para estimativa dos resultados futuros com propósito de redução do descarte de matérias primas (considerando que as variáveis selecionadas para regressão apresentam variação mensal dependendo das condições do mercado, demandas de clientes, cenário econômico e processos internos complexos). A Tabela 19 traz a variação entre o valor previsto (estimado) e o realizado mensalmente para o descarte de matérias primas.

<b>PERÍODO</b>	<b>DESCARTE PREVISTO (Y)</b>	<b>DESCARTE REALIZADO</b>	<b>REALIZADO vs. PREVISTO</b>
mai/17	13.509	12.813	-5,2%
jun/17	7.817	8.170	4,5%
jul/17	8.215	8.602	4,7%
ago/17	9.030	8.784	-2,7%
set/17	1.184	1.291	9,0%
out/17	4.932	4.999	1,4%

Tabela 19: Valores previstos e realizados mensalmente para o descarte de matérias primas

Fonte: Dados da empresa

Embora não existam objetivos formais de redução definidos para o ano de 2017 (apenas para 2018), é possível observar uma mudança no comportamento do descarte de produtos vencidos a partir do início da implantação do método e nos seis meses subsequentes. A Figura 3 evidencia que, muito embora não seja possível comparar o resultado obtido com uma meta formal, e considerando que o comportamento da variável Y (descarte de matérias primas deterioradas) no período anterior a implantação do método apresente uma grande variabilidade nos resultados apontados mensalmente (maio de 2016 a abril de 2017), é possível perceber uma redução no valor médio mensal do descarte de matérias primas vencidas de 25,8% após a implantação do método.

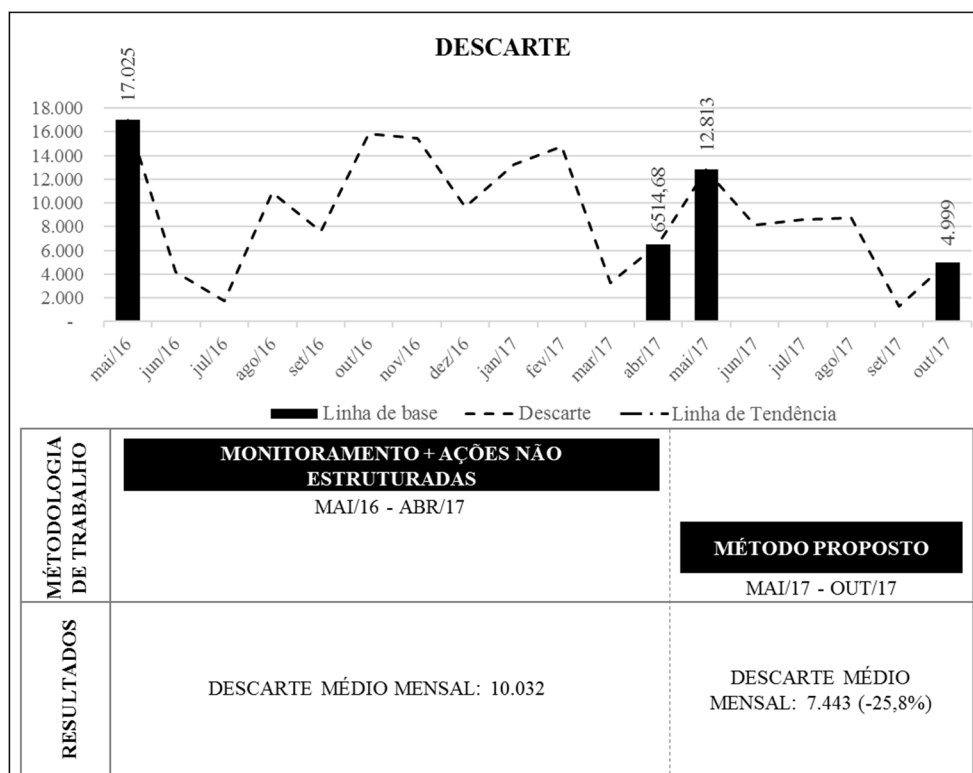


Figura 3: Resultados obtidos antes e depois da implantação do método proposto

Fonte: Dados da empresa

Dada a amplitude da variação nos valores de matéria prima descartadas de maio de 2016 a abril de 2017 e a complexidade da análise dos resultados, o pesquisador optou pelo ajuste de uma linha de tendência para comparar as duas séries temporais (descarte de matéria prima deteriorada antes e depois da aplicação do método), como forma de reduzir a subjetividade na análise da eficácia do método proposto. O tipo de linha de tendência que mostrou o melhor ajuste às duas séries temporais foi a polinomial, devido a flutuação dos dados coletados. O ajuste da linha de tendência aos conjuntos de dados foi mensurado através do  $R^2$ . Por critério do pesquisador, a ordem da polinomial foi determinada pelo número de flutuações nos dados (picos e vales que aparecem na curva). O resultado da aplicação da linha de tendência pode ser observado no Figura 4.




Figura 4: Ajuste de linha de tendência polinomial nas duas séries temporais  
Fonte: Dados da empresa

Face ao resultado das análises, formou-se consenso entre os gestores da empresa e o time multifuncional de que a implantação do método proposto conduziu a uma redução significativa do descarte médio mensal de matérias primas vencidas, contribuiu para redução da amplitude dos descartes mensais, e apresentou uma perspectiva de queda nos valores de descarte futuros. Conclui-se, portanto, que os resultados obtidos não seriam tão expressivos caso o método proposto não tivesse sido implantado.

## 6. DISCUSSÃO DOS RESULTADOS

Ambas as empresas são fornecedoras de bens de consumo para redes varejistas, porém, de segmentos diferentes do varejo (no Estudo de Caso 1, eletroeletrônico, móveis, materiais de construção e especializado; no Estudo de Caso 2, farmacêutico, alimentar e vestuário). Embora os produtos e canais do varejo sejam diferentes, as regras à que estão sujeitas são muito similares no que tange a negociações comerciais, devolução de produtos e necessidade de lançamentos constantes de novos produtos.

Com relação às regras e procedimentos que podem gerar estoques obsoletos ou deteriorados, as empresas dos Estudos de Caso 1 e 2 apresentam diversas semelhanças. Ambas as empresas utilizam o FIFO como uma das ferramentas para gestão do inventário, estão sujeitas a devoluções de clientes, possuem processos internos de gestão de portfólio, procedimento de gestão dos produtos danificados nos armazéns, política de controle de devolução de produtos danificados no transporte, processo de retrabalho de produtos devolvidos, processo de gestão do agendamento de entregas para clientes e política de segregação de itens no estoque em diferentes armazéns de acordo com a disponibilidade dos mesmos para venda. Estas regras e procedimentos, em menor ou maior grau, impactam o risco de obsolescência ou deterioração do inventário nas duas empresas objeto deste trabalho, e podem estar presentes em outras empresas onde este método possa ser implantado.

A devolução de produtos por parte dos varejistas, por tratar-se de fato imprevisto e alheio à vontade da indústria, apresentou-se como uma fonte importante de estoques obsoletos ou deteriorados. No Estudo de Caso 2, principalmente, considerando que os produtos fabricados pela indústria são perecíveis e que a totalidade dos clientes possui regras explícitas quanto à validade mínima para o recebimento dos produtos, o risco de deterioração iminente do estoque devolvido é grande. Em ambos os casos, a definição de procedimentos claros para devolução dos produtos é imprescindível para restringir a quantidade de devoluções de clientes.

O FIFO é uma técnica utilizada pelas indústrias de ambos os estudos de caso para garantir que o estoque mais antigo de determinado item seja comercializado primeiro. Porém, a lógica da maioria dos sistemas WMS considera a data de entrada do item no armazém (e não a data de apontamento da ordem de produção do produto) para efeitos de FIFO, o que compromete a eficácia da ferramenta. O método utilizado pela indústria do Estudo de Caso 2, de monitorar os itens em estoque por lote de produção (por exigência da ANVISA) mostrou-se muito mais adequado para evitar as baixas contábeis de estoque por obsolescência ou deterioração. Porém, o sistema da empresa (WMS ou ERP) devem ser preparados para identificar e correlacionar



cada item a um determinado lote (de produção ou compra), o que pode demandar a customização de sistemas informatizados.

Ambos os estudos de caso apresentam similaridade quanto aos fatos geradores de obsolescência ou deterioração do estoque. O método de gestão do FIFO nos armazéns, as devoluções de clientes, a grande quantidade de itens importados com longo lead time, a introdução de novos produtos antes de eliminar ou reduzir o estoque dos produtos atuais que seriam substituídos e a falta de gestão dos produtos devolvidos por danos no transporte ou por movimentação interna nos armazéns estão presentes em ambas das indústrias onde o método foi implantado. Embora a empresa foco do Estudo de Caso 2 não siga o padrão de contabilidade internacional IFRS, a preocupação com a integridade do inventário como ativo da empresa é muito presente, e as baixas contábeis por deterioração do estoque são monitoradas através de indicadores gerenciais, buscando tanto a proteção do estoque quanto do resultado financeiro. A preocupação com a integridade do inventário, em maior ou menor grau, está presente nas indústrias em geral.

Há, porém, uma diferença importante com relação à natureza dos produtos, visto que o Estudo de Caso 1 trata de bens duráveis e o Estudo de Caso 2 de itens perecíveis. No segundo estudo de caso, o lote mínimo de compra aparece como fator contribuinte para a deterioração do estoque. Por sua vez, o tamanho do lote de produção de produtos acabados, que poderia trazer impactos semelhantes no primeiro estudo de caso, não se mostrou relevante para o produto em questão. Porém, na aplicação do método em outras indústrias ou produtos, este fator pode ter sua importância majorada. Por fim, a diferença quanto à natureza dos produtos não impediu a implantação do método, que se mostrou adequado para ambas as situações como ferramenta para reduzir as baixas contábeis de inventário.

Outra diferença significativa entre os estudos de caso é com relação ao tipo de item objeto de estudo: Enquanto o Estudo de Caso 1 trata de produtos acabados, o Estudo de Caso 2 foca nas matérias primas. Como os impactos da obsolescência ou deterioração são os mesmos para os dois tipos de item (baixa contábil do estoque), o método se mostrou capaz de projetar tanto o risco de obsolescência quanto o risco de deterioração através da regressão PLS.

Em ambos os estudos de caso foi necessária a classificação dos itens em classes ou grupos para definição de ações corretivas de forma mais robusta e direcionada à causa raiz dos problemas. Enquanto no Estudo de Caso 1 o cadastro dos itens no sistema ERP continha uma classificação detalhada dos itens em estoque por tipo ou função, esta classificação não existia na empresa objeto do Estudo de Caso 2. Esta restrição foi contornada de forma satisfatória com a aplicação da análise discriminante para classificação dos itens. A análise discriminante,

aplicada no Estudo de Caso 2 para classificar os itens em função de seu histórico de descarte por deterioração, pode ser útil também para classificar os itens função de sua natureza, função ou tipo em outras empresas onde o método for implantado.

Enquanto no Estudo de Caso 1 o sistema ERP não dispunha de informações estruturadas sobre a idade do inventário (demandando a criação de tabelas e relatórios no para classificação dos produtos em faixas de idade), esta informação já estava disponível e estruturada no sistema ERP do Estudo de Caso 2 (por exigência da ANVISA para o controle de lotes de matérias primas e produtos acabados). Uma diferença operacional importante com relação à idade do inventário nos diferentes estudos de caso diz respeito à natureza das ações propostas para redução do risco de obsolescência e/ou deterioração do estoque. Enquanto na indústria de bens de consumo duráveis (Estudo de Caso 1) a idade do inventário foi fundamental para a definição de ações e políticas comerciais diferenciadas para venda dos produtos (quanto mais antigo o produto ou defasada a linha em relação à oferta média de mercado, menor deverá ser o preço de venda), no caso da indústria de bens de consumo não duráveis (Estudo de Caso 2) a deterioração está diretamente relacionada à perda total do valor de inventário de determinado item (não impacta o preço de venda dos produtos acabados, porém direciona ações para venda do estoque excessivo de matérias primas ou a produção de um determinado produto que utilize as matérias primas a vencer).

Note-se que tanto no Estudo de Caso 1 quanto no Estudo de Caso 2 foram selecionadas variáveis que representam, total ou parcialmente, o volume de vendas e o inventário da empresa, fatores que contribuem diretamente para o risco de obsolescência ou deterioração do inventário. É importante observar que algumas variáveis comuns em ambientes industriais costumam ser de fácil obtenção e podem trazer informações adicionais para tomada de decisão. Como exemplo, no Estudo de Caso 1 a variável C3 (volume de produção), descartada na etapa de seleção das variáveis mais relevantes com propósito de predição, pode contribuir para o resultado final da análise agregando apenas uma variável adicional. Esta mesma variável foi mantida no Estudo de Caso 2 (X8), e se mostrou relevante para a análise em questão. Desta forma, como critério do pesquisador, pode optar-se por manter a variável volume de produção em futuras análises com vistas a aplicar este modelo em outras indústrias.

A projeção do risco futuro de obsolescência ou deterioração através da regressão PLS mostrou-se adequada para os objetivos de ambos os estudos de caso. As diferenças de ramo de indústria, tipo de produto ou natureza do item (produto acabado ou matéria prima) não comprometeram a aplicação do método nas duas indústrias. O fato da regressão PLS poder ser aplicada em

situações onde os preditores são altamente colineares, onde existam mais preditores do que observações e onde os preditores possam ser medidos com erro contribui para que o método possa ser aplicado em diferentes tipos de ambiente, produtos ou empresas.

## 7. CONCLUSÃO

A aplicação do método proposto em duas situações distintas mostra que o conceito originalmente criado para projetar o risco de obsolescência do inventário pode ser aplicado tanto para a projeção do risco de obsolescência quanto para o risco de deterioração do inventário ao longo do tempo, visto que ambos os aspectos – obsolescência e deterioração – estão ligados diretamente a perdas ou baixas contábeis com reflexo no resultado financeiro das empresas.

A projeção do risco de obsolescência e/ou deterioração através da regressão PLS, sob a ótica dos gestores das duas empresas onde o método foi implantado, apresentou resultados coerentes e com um nível de precisão adequado para tomada de decisão. A aplicação do método auxiliou na redução do inventário exposto ao risco de obsolescência no Estudo de Caso 1, através da definição de ações precisas para cada grupo de item e faixa de idade, conduzindo o projeto de redução do inventário acima de 180 dias a resultados satisfatórios. Já no Estudo de Caso 2, a implantação da metodologia contribuiu para a redução do descarte de matérias primas vencidas e a identificação dos itens com maior risco de deterioração através da análise discriminante.

A classificação do estoque por tipo de item mostrou-se fundamental para aplicação de métodos e ações mais adequados para cada grupo. Embora os especialistas da empresa possuíssem conceitos prévios com relação aos fatores que conduzem à obsolescência ou deterioração do inventário, a análise com base em fatos e dados, relacionando as perdas por obsolescência ou deterioração ao tipo de item ou à sua idade, tornam mais clara as causas da perda do inventário por obsolescência ou deterioração. No Estudo de Caso 2, embora a complexidade tenha sido maior devido a inexistência de classificação dos itens e de uma relação clara entre o tipo de item e o maior ou menor risco de descarte, esta dificuldade foi plenamente contornada com a utilização da análise discriminante, classificando as matérias primas em grupos em função do histórico de deterioração anterior e a definição de ações específicas para as matérias primas classificadas no grupo com maior risco de deterioração. A análise discriminante mostrou-se uma ferramenta adequada para implantação do método proposto em situações onde não houver classificação prévia dos itens ou correlação clara entre o tipo de item e o risco de obsolescência ou degradação.

A compreensão da idade do inventário por faixas de idade, a classificação dos itens conforme seu tipo e a relação destas informações com o risco de obsolescência ou deterioração do inventário contribuiu sobremaneira para os resultados obtidos. Este conhecimento, aliado à aplicação de ferramentas de seleção de variáveis, proporcionou a definição de conjuntos de

variáveis apropriados para os objetivos dos projetos, otimizando recursos, maximizando os resultados e aumentando as chances de êxito.

Na maioria das situações, as estimativas futuras são realizadas com base nos dados históricos, nas melhores estimativas de especialistas ou em função de resultados futuros comprometidos com a alta gestão ou investidores da empresa. O método proposto neste trabalho possibilita o controle prévio dos resultados projetados e a adoção de medidas corretivas ao longo do processo sempre que necessário, tornando a classificação, projeção e controle da obsolescência de inventários um processo flexível e adaptativo, apto a conduzir a empresa os objetivos propostos de forma otimizada. Além disso, o a projeção do resultado futuro permite aos gestores e especialistas da empresa a atualização do planejamento financeiro sempre que necessário. Para efeitos de padronização da análise, sugere-se que a rotina de verificar o planejado vs. realizado ocorra mensalmente, após o fechamento contábil de cada mês, utilizando variáveis atualizadas com a última previsão (*forecast*) da empresa para refinar ainda mais as projeções futuras.

Embora os objetivos iniciais do trabalho não considerarem impactos ecológicos, a aplicação do método no Estudo de Caso 2 evidenciou que a redução do descarte de matérias primas vencidas tem impacto significativo nos indicadores ambientais, além de propiciar a redução dos custos inerentes à correta destinação dos resíduos industriais, abrindo a oportunidade para futuros trabalhos neste contexto utilizando a metodologia proposta. Em ambos os estudos de caso, as indústrias possuíam como principal cliente redes varejistas, as quais, respeitadas as particularidades inerentes ao tipo de produto, possuem requisitos comuns. A aplicação deste método em outros tipos de indústria ou em situações onde os clientes possuam requisitos e dinâmicas comerciais diferentes demandará novas análises, caracterizando uma oportunidade para futuros trabalhos utilizando a metodologia proposta.

## REFERÊNCIAS

- ABDI, H.; WILLIAMS, L. J. **Partial least squares methods**: partial least squares correlation and partial least square regression. *Computational Toxicology: Volume II*, p. 549-579, 2013.
- AGRESTI, A.; KATERI, M. **Categorical data analysis**. Berlin/Heidelberg: Springer, 2011.
- AL-KHEDHAIRI, A. **Optimal control of a production inventory system with generalized exponential distributed deterioration**. Department of Statistics and Operations Research. College of Science. King Saud University, Saudi Arabia, 2010.
- ALGHAZZAWI, A.; LENNOX, B. **Monitoring a complex refining process using multivariate statistics**. *Control Engineering Practice*, v. 16, n. 3, p. 294-307, 2008.
- ALGHAZZAWI, A.; LENNOX, B. **Model predictive control monitoring using multivariate statistics**. *Journal of Process Control*, 19(2), 314-327, 2009.
- ANDERSEN, C. M.; BRO, R. **Variable selection in regression - a tutorial**. *Journal of Chemometrics*, 24(11-12), 728-737, 2010.
- ANTONY, J. **Six sigma for service processes**. *Business Process Management Journal*, 12(2), 234-248, 2006.
- ANZANELLO, M. J. **Seleção de variáveis para categorização de amostras químicas**. *Eclética Química*, 36(4), 2011.
- ANZANELLO, M. J. **Seleção de variáveis para classificação de bateladas produtivas com base em múltiplos critérios**. *Production Journal*, 23(4), 858-865, 2013.
- ANZANELLO, M. J.; ALBIN, S. L.; CHAOVALITWONGSE, W. A. **Selecting the best variables for classifying production batches into two quality levels**. *Chemometrics and Intelligent Laboratory Systems*, 97(2), 111-117, 2009.
- ARAÚJO, M. G.; QUEIROZ, J. V.; LIMA, J. C. F.; FERNANDES, G.; QUEIROZ, F. C. B. P.; FURUKAVA, M. **Aplicação do ciclo PDCA na elaboração de um plano estratégico e implementação da Curva ABC como ferramenta de suporte para o gerenciamento de estoques de uma distribuidora de alimentos hospitalares**. *Revista Espacios*, Vol. 37 (Nº 13), 2016.
- AYRES, M.; AYRES JÚNIOR, M.; AYRES, D. L.; SANTOS, A. D. A. **Aplicações estatísticas nas áreas das ciências bio-médicas**. Instituto Mamirauá, Belém, 2007.
- AZIZ, M. A.; DAR, H. A. **Predicting corporate bankruptcy: where we stand?** *Corporate Governance: The international Journal of Business in Society*, 6(1), 18-33, 2006.
- BAKKE, H. A.; LEITE, A. D. M.; SILVA, L. D. **Estatística multivariada: aplicação da análise fatorial na engenharia de produção**. *Revista Gestão Industrial*, 4(4), 1-14, 2008.
- BAKKER, M.; RIEZEBOS, J.; TEUNTER, R. H. **Review of inventory systems with deterioration since 2001**. *European Journal of Operational Research*, 221(2), 275-284, 2012.
- BALCAEN, S.; OOGHE, H. **35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems**. *The British Accounting Review*, 38(1), 63-93, 2006.

BARTELS, B.; ERMEL, U.; SANDBORN, P.; PECHT, M. G. **Strategies to the Prediction, Mitigation and Management of Product Obsolescence**. 1ª ed. Hoboken, New Jersey (USA): John Wiley & Sons Inc., 2012.

BATTINI, D.; PERSONA, A.; SGARBOSSA, F. A. **Sustainable EOQ model**: theoretical formulation and applications. *International Journal of Production Economics*, 149, 145-153, 2014.

BEAMON, B. M. **Supply chain design and analysis**: Models and methods. *International Journal of Production Economics*, 55(3), 281-294, 1998.

BEAMON, B. M. **Measuring supply chain performance**. *International Journal of Operations & Production Management*, 19(3), 275-292, 1999.

BLUM, A. L.; LANGLEY, P. **Selection of relevant features and examples in machine learning**. *Artificial Intelligence*, 97(1), 245-271, 1997.

BOISBUNON, A.; CANU, S.; FOURDRINIER, D.; STRAWDERMAN, W.; Wells, M. T. **AIC, Cp and estimators of loss for elliptically symmetric distributions**. arXiv preprint arXiv:1308.2766, 2013.

BONNEY, M.; JABER, M. Y. **Environmentally responsible inventory models**: Non-classical models for a non-classical era. *International Journal of Production Economics*, 133(1), 43-53, 2011.

BOULESTEIX, A. L.; STRIMMER, K. **Partial least squares**: a versatile tool for the analysis of high-dimensional genomic data. *Briefings in bioinformatics*, v. 8, n. 1, p. 32-44, 2006. *Briefings in bioinformatics*, 8(1), 32-44.

BOYLAN, J. E.; SYNTETOS, A. A.; KARAKOSTAS, G. C. **Classification for forecasting and stock control**: a case study. *Journal of the Operational Research Society*, 59(4), 473-481, 2008.

BROSOFSKE, K. D.; FROESE, R. E.; FALKOWSKI, M. J.; BANSKOTA, A. **A review of methods for mapping and prediction of inventory attributes for operational forest management**. *Forest Science*, 60(4), 733-756, 2014.

BUTT, T. E.; CAMILLERI, M.; PAUL, P.; JONES, K. G. **Obsolescence types and the built environment - definitions and implications**. *International Journal of Environment and Sustainable Development*, 14(1), 20-39, 2015.

CAKIR, O.; CANBOLAT, M. S. **A web-based decision support system for multi-criteria inventory classification using fuzzy AHP methodology**. *Expert Systems with Applications*, v. 35, n. 3, p. 1367-1378, 2008.

CAMPOS, J. C. **Os impactos da conjuntura macroeconômica sobre o comércio no Brasil**: uma análise empírica das grandes varejistas. Fundação Getúlio Vargas, Rio de Janeiro, 2009.

CELLA, G.; RODRIGUES, J. M.; NIYAMA, J. K. **Contabilidade Internacional-análise dos periódicos internacionais sobre pesquisas em educação contábil face à convergência e globalização**. *Revista Contemporânea de Contabilidade*, v. 8, n. 15, 2011.

CERVO, V. L.; ANZANELLO, M. J. **Seleção de variáveis para clusterização de bateladas produtivas através de ACP e remapeamento kernel**. *Production*, v. 25, n. 4, 2015.

CHAE, B. **Developing key performance indicators for supply chain**: an industry perspective. *Supply Chain Management: An International Journal*, 14(6), 422-428, 2009.

- CHEN, H.; RAMNATH, S.; RANGAN, S.; ROCK, S. **Inventory write-downs in the semiconductor industry**. The Fourth Accounting Research Conference, December 19-20, Gachibowli, Hyderabad, India, 2011.
- CHONG, I. G.; JUN, C. H. **Performance of some variable selection methods when multicollinearity is present**. *Chemometrics and Intelligent Laboratory Systems*, 78(1), 103-112, 2005.
- CHOPRA, S.; SODHI, M. S. **Managing risk to avoid supply-chain breakdown**. *MIT Sloan Management Review*, 46(1), 53, 2004.
- CHUN, H.; KELES, S. **Sparse partial least squares regression for simultaneous dimension reduction and variable selection**. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, v. 72, n. 1, p. 3-25, 2010.
- CHUNG, K.; CÁRDENAS-BARRÓN, L. E.; TING, P. **An inventory model with non-instantaneous receipt and exponentially deteriorating items for an integrated three layer supply chain system under two levels of trade credit**. *International Journal of Production Economics*, v. 155, p. 310-317, 2014.
- CLAASSEN, M. J.; VAN WEELE, A. J.; VAN RAAIJ, E. M. **Performance outcomes and success factors of vendor managed inventory (VMI)**. *Supply Chain Management: An International Journal*, 13(6), 406-414, 2008.
- DASH, M.; LIU, H. **Consistency-based search in feature selection**. *Artificial Intelligence*, 151(1), 155-176, 2003.
- DENHAM, M. C. **Choosing the number of factors in partial least squares regression: estimating and minimizing the mean squared error of prediction**. *Journal of Chemometrics*, v. 14, n. 4, p. 351-361, 2000.
- DORMANN, C. F.; ELITH, J.; BACHER, S.; BUCHMANN, C.; CARL, G.; CARRÉ, G.; MÜNKEMÜLLER, T. **Collinearity: a review of methods to deal with it and a simulation study evaluating their performance**. *Ecography*, v. 36, n. 1, p. 27-46, 2013.
- ERLANDSSON, B.; DUHAN, J. **A Pragmatic Approach to Inventory Management**. 2008.
- FARENHORST, A.; PAPIERNIK, S. K.; SAIYED, I.; MESSING, P.; STEPHENS, K. D.; SCHUMACHER, J. A.; LOBB, D. A.; LI, S.; LINDSTROM, M. J.; SCHUMACHER, T. E. **Herbicide sorption coefficients in relation to soil properties and terrain attributes on a cultivated prairie**. *Journal of environmental quality*, v. 37, n. 3, p. 1201-1208, 2008.
- FASSNACHT, F. E.; NEUMANN, C.; FÖRSTER, M.; BUDDENBAUM, H.; GHOSH, A.; CLASEN, A.; KOCH, B. **Comparison of feature reduction algorithms for classifying tree species with hyperspectral data on three central European test sites**. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, n. 6, p. 2547-2561, 2014.
- FERRER, A.; AGUADO, D.; VIDAL-PUIG, S.; PRATS, J. M.; ZARZO, M. **PLS: A versatile tool for industrial process improvement and optimization**. *Applied Stochastic Models in Business and Industry*, 24(6), 551-567, 2008.
- FISHER, M.; RAJARAM, K.; RAMAN, A. **Optimizing inventory replenishment of retail fashion products**. *Manufacturing & service operations management*, v. 3, n. 3, p. 230-241, 2001.
- FISHER, M. L. **What is the right supply chain for your product**. *Operations Management: Critical Perspectives on Business and Management*, 4, 73, 2003.



- FLORIANO, E. P.; Müller, I.; Finger, C. A. G.; Schneider, P. R. **Ajuste e seleção de modelos tradicionais para série temporal de dados de altura de árvores**. *Ciência Florestal*, v. 16, n. 2, 2006.
- FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. **The elements of statistical learning**. New York: Springer series in statistics, 2001.
- GAUCHI, J. P.; CHAGNON, P. **Comparison of selection methods of explanatory variables in PLS regression with application to manufacturing process data**. *Chemometrics and Intelligent Laboratory Systems*, 58(2), 171-193, 2001.
- GELADI, P.; KOWALSKI, B. R. **Partial least-squares regression: a tutorial**. *Analytica Chimica Acta*, v. 185, p. 1-17, 1986.
- GIL, A. **Como elaborar projetos de pesquisa**. Atlas. 2010.
- GIMENES, R. M. T.; URIBE-OPAZO, M. A. **Previsão de insolvência de cooperativas agropecuárias por meio de modelos multivariados**. *Revista da FAE*, v. 4, n. 3, 2001.
- GNANA, D. A. A.; APPAVU, S.; LEAVLINE, E. J. **Literature Review on Feature Selection Methods for High-Dimensional Data**. *Methods*, 136(1), 2016.
- GOYAL, S. K.; GIRI, B. C. **Recent trends in modeling of deteriorating inventory**. *European Journal of operational research*, v. 134, n. 1, p. 1-16, 2001.
- GRÖMPING, U. **Relative importance for linear regression in R: the package relaimpo**. *Journal of statistical software*, v. 17, n. 1, p. 1-27, 2006.
- GUIMARÃES, A.; MOREIRA, T. B. S. **Previsão de Insolvência: Um Modelo Baseado em Índices Contábeis com Utilização da Análise Discriminante** (Insolvency Predictor: A Model Based on Account Index with Application of Discriminant Analysis). 2008.
- GUYON, I.; ELISSEEFF, A. **An introduction to variable and feature selection**. *The Journal of Machine Learning Research*, 3, 1157-1182, 2003.
- HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; AND TATHAM, R. L. **Multivariate Data Analysis** Seventh Edition. Pearson Education, New Jersey, 2009.
- HENDRIKS, M. M.; VAN EEUWIJK, F. A.; JELLEMA, R. H.; WESTERHUIS, J. A.; REIJMERS, T. H.; HOEFSLOOT, H. C.; SMILDE, A. K. **Data-processing strategies for metabolomics studies**. *TrAC Trends in Analytical Chemistry*, v. 30, n. 10, p. 1685-1698, 2011.
- HENSELER, J.; RINGLE, C. M.; SINKOVICS, R. R. **The use of partial least squares path modeling in international marketing**. *Advances in International Marketing*, 20(1), 277-319, 2009.
- HÖSKULDSSON, A. **Variable and subset selection in PLS regression**. *Chemometrics and intelligent laboratory systems*, 55(1), 23-38, 2001.
- HUANG, S. M.; TSAI, C. F.; YEN, D. C.; CHENG, Y. L. **A hybrid financial analysis model for business failure prediction**. *Expert Systems With Applications*, 35(3), 1034-1040, 2008.
- HUANG, W.; NAKAMORI, Y.; WANG, S. Y. **Forecasting stock market movement direction with support vector machine**. *Computers & Operations Research*, 32(10), 2513-2522, 2005.
- INDAHL, U. **A twist to partial least squares regression**. *Journal of Chemometrics*, v. 19, n. 1, p. 32-44, 2005.

- JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning** (Vol. 6). New York: Springer, 2013.
- JANSSEN, L.; CLAUS, T.; SAUER, J. **Literature review of deteriorating inventory models by key topics from 2012 to 2015**. International Journal of Production Economics, 182, 86-112, 2016.
- JENNINGS, C. P. **Forecasting obsolescence risk and product lifecycle with machine learning**. Graduate Theses and Dissertations, 14825, Iowa State University, 2015.
- JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**, 6<sup>a</sup> ed. Upper Saddle River, NJ: Prentice Hall, 2007.
- JONES, C. S.; TUZEL, S. **Inventory investment and the cost of capital**. Journal of Financial Economics, v. 107, n. 3, p. 557-579, 2013.
- JUNIOR, A.; NOCERA, P. **Gestão de estoque no setor de varejo calçadista: abordagem via análise multivariada e teoria do controle ótimo**. 2014.
- KALAM, A.; SAMAL, D.; SAHU, S. K.; MISHRA, M. **A production lot-size inventory model for Weibull deteriorating item with quadratic demand, quadratic production and shortages**. International Journal of Computer Science & Communication, v. 1, n. 1, p. 259-262, 2010.
- KAMAU, L. W.; KAGIRI, A. W. **Influence of inventory management practices on organizational competitiveness: A case of Safaricom Kenya Ltd**. International Academic Journal of Procurement and Supply Chain Management, v. 1, n. 5, p. 72-98, 2015.
- KARMAKAR, B.; CHOUDHURY, K. D. **A review on inventory models for deteriorating items with shortages**. Assam University Journal of Science and Technology, v. 6, n. 2, p. 51-59, 2010.
- KASZMAR, I. K.; GONÇALVES, B. M. L. **Regressão múltipla: uma digressão sobre seus usos**. Instituto Business Consultoria Internacional, Rio de Janeiro, nd, 20p, 2011.
- KATOK, E.; LATHROP, A.; TARANTINO, W.; XU, S. H. **Jeppesen uses a dynamic-programming-based DSS to manage inventory**. Interfaces, v. 31, n. 6, p. 54-65, 2001.
- KAUFMANN, L.; GAECKLER, J. **A structured review of partial least squares in supply chain management research**. Journal of Purchasing and Supply Management, 21(4), 259-272, 2015.
- KESSLER, T.; BRENDL, J. **Planned Obsolescence and Product-Service Systems: Linking Two Contradictory Business Models**. Journal of Competence-based Strategic Management, 8, 29-52, 2016.
- KETTANEH, N.; BERGLUND, A.; WOLD, S. **PCA and PLS with very large data sets**. Computational Statistics & Data Analysis, 48(1), 69-85, 2005.
- KHOLOPANE, P. **The Effect of the Implementation of Six Sigma in Reducing Obsolete Stock and Controlling Stock Inventory at a Flavor Manufacturing Company: A Case Study**. In: Proceedings of the International Multi Conference of Engineers and Computer Scientists (Vol. 2), 2016.
- KRAJČOVIČ, M.; PLINTA, D. **Comprehensive approach to the inventory control system improvement**. Management and Production Engineering Review, 3(3), 34-44, 2012.

- KUMAR, U. D.; SARANGA, H. **Optimal selection of obsolescence mitigation strategies using a restless bandit model**. *European Journal of Operational Research*, 200(1), 170-180, 2010.
- LAMBERT, D. M.; STOCK, J. R.; ELLRAM, L. M. **Fundamentals of logistics management**. McGraw-Hill/Irwin, 1998.
- LATINO, R. J.; LATINO, K. C.; LATINO, M. A. **Root cause analysis: improving performance for bottom-line results**, 3<sup>a</sup> ed. Boca Raton, FL: CRC Press, 2006.
- LARSON, C. R.; TURCIC, D.; ZHANG, F. **Inventory write-downs, sales growth, and ordering policy: An empirical investigation**. SSRN Working Paper Series, 2011.
- LI, L.; SHEN, C.; WANG, L.; ZHENG, L.; JIANG, Y.; TANG, L.; TANG, J. **iMiner: mining inventory data for intelligent management**. In: *Proceedings of the 23rd ACM International Conference on Conference on Information and Knowledge Management*, p. 2057-2059. ACM, 2014.
- LILAND, K. H. **Multivariate methods in metabolomics—from pre-processing to dimension reduction and statistical analysis**. *TrAC Trends in Analytical Chemistry*, 30(6), 827-841, 2011.
- LIU, H.; YU, L. **Toward integrating feature selection algorithms for classification and clustering**. *IEEE Transactions on Knowledge and Data Engineering*, 17(4), 491-502, 2005.
- LIU, R. Y.; PARELIUS, J. M.; SINGH, K. **Multivariate analysis by data depth: descriptive statistics, graphics and inference (with discussion and a rejoinder by Liu and Singh)**. *The annals of statistics*, v. 27, n. 3, p. 783-858, 1999.
- LORETO, E. M. S. **Sistemática para seleção de variáveis e determinação da condição ótima de operação em processos contínuos multivariados em múltiplos estágios**. Universidade Federal do Rio Grande do Sul, 2014.
- MALLOWS, C. L. **Some comments on Cp**. *Technometrics*, v. 15, n. 4, p. 661-675, 1973.
- MARCOULIDES, G. A.; CHIN, W. W.; SAUNDERS, C. **A critical look at partial least squares modeling**. *Mis Quarterly*, 33(1), 171-175, 2009.
- MÁRIO, P. D. C. **Contribuição ao estudo da solvência empresarial: uma análise de modelos de previsão-estudo exploratório aplicado em empresas mineiras (doctoral dissertation, Universidade de São Paulo)**, 2002.
- MASIERO, M. S.; ANZANELLO, M. J. **Seleção de variáveis para predição utilizando regressão linear em processos logísticos de distribuição**. Universidade Federal do Rio Grande do Sul, 2011.
- MATEOS-APARICIO, G. **Partial least squares (PLS) methods: Origins, evolution, and application to social sciences**. *Communications in Statistics-Theory and Methods*, 40(13), 2305-2317, 2011.
- MAZZILLO JÚNIOR, C. A.; ANZANELLO, M. J. **Sistemática de seleção de variáveis para classificação de produtos em categorias de modelos de reposição**. *Gestão & Produção*, v. 22, n. 1, p. 201-212, 2015.
- MCINTOSH, C. N.; EDWARDS, J. R.; ANTONAKIS, J. **Reflections on partial least squares path modeling**. *Organizational Research Methods*, v. 17, n. 2, p. 210-251, 2014.

- MEHMOOD, T.; LILAND, K. H.; SNIPEN, L.; SÆBØ, S. **A review of variable selection methods in partial least squares regression**. *Chemometrics and Intelligent Laboratory Systems*, 118, 62-69, 2012.
- MELO, A. S.; HEPP, L. U. **Ferramentas estatísticas para análises de dados provenientes de biomonitoramento**. *Oecologia Brasiliensis*, 12(3), 8, 2008.
- MELO, C. P.; CARAMORI, E.J. **PDCA Método de melhorias para empresas de manufatura – versão 2.0**. Belo Horizonte: Fundação de Desenvolvimento Gerencial, 2001.
- MENG, X.; THÖRNBERG, B.; OLSSON, L. **Strategic proactive obsolescence management model**. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 4(6), 1099-1108, 2014.
- MICHALSKI, G. **Corporate inventory management with value maximization in view**. *Zemedelska Ekonomika-Praha*, v. 54, n. 5, p. 187, 2008.
- MILETIC, I.; QUINN, S.; DUDZIC, M.; VACULIK, V.; CHAMPAGNE, M. **An industrial perspective on implementing on-line applications of multivariate statistics**. *Journal of Process Control*, 14(8), 821-836, 2004.
- MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Belo Horizonte: UFMG, 2005.
- MOLDAN, B.; JANOUŠKOVÁ, S.; HÁK, T. **How to understand and measure environmental sustainability: Indicators and targets**. *Ecological Indicators*, 17, 4-13, 2012.
- MONTGOMERY, D. C. **Design and analysis of experiments**, 5<sup>a</sup> ed. John Wiley & Sons, 2008.
- NAGARE, M.; DUTTA, P. **Continuous review model for perishable products with inventory dependent demand**. In: *Proceedings of the International MultiConference of Engineers and Computer Scientists*. 2012.
- NAKAGAWA, S.; SCHIELZETH, H. **A general and simple method for obtaining  $R^2$  from generalized linear mixed-effects models**. *Methods in Ecology and Evolution*, 4(2), 133-142, 2013.
- NATHANS, L. L.; OSWALD, F. L.; NIMON, K. **Interpreting multiple linear regression: A guidebook of variable importance**. *Practical Assessment, Research & Evaluation*, v. 17, n. 9, 2012.
- NENES, G.; PANAGIOTIDOU, S.; TAGARAS, G. **Inventory management of multiple items with irregular demand: A case study**. *European Journal of Operational Research*, 205(2), 313-324, 2010.
- NG, W. L. **A simple classifier for multiple criteria ABC analysis**. *European Journal of Operational Research*, v. 177, n. 1, p. 344-353, 2007.
- NIMON, K. F.; OSWALD, F. L. **Understanding the results of multiple linear regression: Beyond standardized regression coefficients**. *Organizational Research Methods*, v. 16, n. 4, p. 650-674, 2013.
- OLIVEIRA, A. B. **Melhoria do processo Hatschek, por meio de tratamento de dados históricos, para fabricação de telhas onduladas**. 2010. Tese de Doutorado. Universidade de São Paulo.
- ORELIEN, J. G.; EDWARDS, L. J. **Fixed-effect variable selection in linear mixed models using  $R^2$  statistics**. *Computational Statistics & Data Analysis*, 52(4), 1896-1907, 2008.

- PANIGRAHI, A. K. **Relationship between inventory management and profitability: An empirical analysis of Indian cement companies.** Asia Pacific Journal of Marketing & Management Review, 2(7), 2013.
- PARK, C. H.; PARK, H. **A comparison of generalized linear discriminant analysis algorithms.** Pattern Recognition, v. 41, n. 3, p. 1083-1097, 2007.
- PINÇE, Ç.; DEKKER, R. **An inventory model for slow moving items subject to obsolescence.** European Journal of Operational Research, 213(1), 83-95, 2011.
- PINGLE, P. **Selection of obsolescence resolution strategy based on a multi criteria decision model** (Doctoral dissertation, Iowa State University), 2015.
- PIROUZ, D. M. **An overview of partial least squares.** 2006.
- PORTER, M. E. **Vantagem competitiva: criando e sustentando um desempenho superior.** Rio de Janeiro: Campus, 1992.
- POURAKBAR, M.; FRENK, J. B. G.; DEKKER, R. **End-of-Life Inventory Decisions for Consumer Electronics Service Parts.** Production and Operations Management, 21(5), 889-906, 2012.
- RAMANATHAN, R. **ABC inventory classification with multiple-criteria using weighted linear optimization.** Computers & Operations Research, v. 33, n. 3, p. 695-700, 2006.
- RAZA, B.; KARIM, U.; HUSSAIN, D. **Inventory Aging: An Impediment to the Value Chain - A Case Related to the Automotive Industry,** 2017.
- RENCHER, A. C. **Methods of multivariate analysis.** John Wiley & Sons, 2003.
- ROSIPAL, R.; KRÄMER, N. **Overview and recent advances in partial least squares.** Lecture notes in Computer Science, v. 3940, p. 34, 2006.
- ROY, P. P.; ROY, K. **On some aspects of variable selection for partial least squares regression models.** QSAR & Combinatorial Science, 27(3), 302-313, 2008.
- SAEYS, Y.; INZA, I.; LARRAÑAGA, P. **A review of feature selection techniques in bioinformatics.** Bioinformatics, 23(19), 2507-2517, 2007.
- SAMANTA, G. P.; BHOWMICK, J. **A Deterministic Inventory System with Weibull Distribution Deterioration and Ramp Type Demand Rate.** Electronic Journal of Applied Statistical Analysis, v. 3, n. 2, p. 92-114, 2010.
- SANDBORN, P.; PRABHAKAR, V.; AHMAD, O. **Forecasting electronic part procurement lifetimes to enable the management of DMSMS obsolescence.** Microelectronics Reliability, 51(2), 392-399, 2011.
- SANTOS, E. A. D.; MIRAGLIA, S. G. E. K. **Arquivos abertos e instrumentos de gestão da qualidade como recursos para a disseminação da informação científica em segurança e saúde no trabalho.** Ciência da Informação, 2009.
- SARKAR, B.; SETT, B. K.; GOSWAMI, A.; SARKAR, S. **Mitigation of high-tech products with probabilistic deterioration and inflations.** American Journal of Industrial and Business Management, v. 5, n. 03, p. 73, 2015.
- SCHIELZETH, H. **Simple means to improve the interpretability of regression coefficients.** Methods in Ecology and Evolution, 1(2), 103-113, 2010.

- SHARMA, S.; SINGH, S. R. **An inventory model for decaying items, considering multi variate consumption rate with partial backlogging**. Indian Journal of Science and Technology, v. 6, n. 7, p. 4870-4880, 2013.
- SILVA, A. F. S.; SILVA, E. P.; DENBERG, M. W. S. **Mensuração do fair value de ativos tangíveis: estoque e ativo imobilizado**. Pensar Contábil, v. 13, n. 51, 2011.
- SILVA, E. L.; MENEZES, E. M. **Metodologia da pesquisa e elaboração de dissertação**, 5ª ed. Florianópolis: Editora UFSC, 2005.
- SINGH, R. K.; GARG, S. K.; DESHMUKH, S. G. **Strategy development by SMEs for competitiveness: a review**. Benchmarking: An International Journal, 15(5), 525-547, 2008.
- SLONE, R. E.; MENTZER, J. T.; DITTMANN, J. P. **Are you the weakest link in your company's supply chain?** Harvard Business Review, v. 85, n. 9, p. 116, 2007.
- SOLOMON, R.; SANDBORN, P. A.; PECHT, M. G. **Electronic part life cycle concepts and obsolescence forecasting**. IEEE Transactions on Components and Packaging Technologies, v. 23, n. 4, p. 707-717, 2000.
- SONG, Y.; LAU, H. C. **A periodic-review inventory model with application to the continuous-review obsolescence problem**. European Journal of Operational Research, 159(1), 110-120, 2004.
- SONG, J. S.; ZIPKIN, P. **Inventory control in a fluctuating demand environment**. Operations Research, 41(2), 351-370, 1993.
- SONG, J. S.; ZIPKIN, P. H. **Managing inventory with the prospect of obsolescence**. Operations Research, 44(1), 215-222, 1996.
- SONI, H.; SHAH, N. H.; JAGGI, C. K. **Inventory models and trade credit: a review**. Control and Cybernetics, v. 39, p. 867-882, 2010.
- SOUZA, A. A. S.; COUTINHO FILHO, F. B. **Harmonização internacional: um estudo sobre as dificuldades de convergência das normas contábeis brasileiras em relação às normas internacionais de contabilidade (IFRS)**. In: Congresso USP de Iniciação Científica em Controladoria e Contabilidade. 2007.
- STANK, T. P.; PAUL DITTMANN, J.; AUTRY, C. W. **The new supply chain agenda: a synopsis and directions for future research**. International Journal of Physical Distribution & Logistics Management, v. 41, n. 10, p. 940-955, 2011.
- STEIN, M.; ANZANELLO, M. J.; KAHMANN, A. **Sistemática para identificação das variáveis preditivas mais relevantes em um processo do setor metal-mecânico**. Revista Gestão Industrial, 10(1), 2014.
- SUGIYAMA, M. **Local fisher discriminant analysis for supervised dimensionality reduction**. In: Proceedings of the 23rd international conference on Machine learning. ACM, 2006. p. 905-912.
- SUGIYAMA, M. **Dimensionality reduction of multimodal labeled data by local fisher discriminant analysis**. Journal of machine learning research, v. 8, n. May, p. 1027-1061, 2007.
- SYNTETOS, A. A.; BABAI, M. Z.; DAVIES, J.; STEPHENSON, D. **Forecasting and stock control: A study in a wholesaling context**. International Journal of Production Economics, 127(1), 103-111, 2010.
- TABACHNICK, B. G.; FIDELL, L. S. **Using multivariate statistics**, 5ª ed. Boston: Allyn & Bacon, 2007.

- TABAKHI, S.; MORADI, P.; AKHLAGHIAN, F. **An unsupervised feature selection algorithm based on ant colony optimization.** Engineering Applications of Artificial Intelligence, 32, 112-123, 2014.
- TANG, O.; MUSA, S. N. **Identifying risk issues and research advancements in supply chain risk management.** International Journal of Production Economics, 133(1), 25-34, 2011.
- TAYAL, S.; SINGH, S. R.; CHAUHAN, A.; SHARMA, R. **A deteriorating production inventory problem with space restriction.** Journal of Information and Optimization Sciences, v. 35, n. 3, p. 203-229, 2014.
- TEIXEIRA, C. F. A.; DAMÉ, R. C. F.; DISCONZI, P. B.; PINTO, M. A. B.; WINKLER, A. S.; SANTOS, J. C. **Estatística de Mallows na seleção de modelos de predição da precipitação média mensal e anual no Rio Grande do Sul.** Revista Agro@ mbiente On-line, v. 7, n. 2, p. 145-153, 2013.
- TENENHAUS, M.; VINZI, V. E.; CHATELIN, Y. M.; LAURO, C. **PLS path modeling.** Computational statistics & data analysis, v. 48, n. 1, p. 159-205, 2005.
- TEUNTER, R. H.; SYNTETOS, A. A.; BABAI, M. Z. **Intermittent demand: Linking forecasting to inventory obsolescence.** European Journal of Operational Research, 214(3), 606-615, 2011.
- THERIVEL, R. **Strategic environmental assessment in action.** Routledge, 2012.
- THOMAZ, J. L. P.; KRONBAUER, C. A.; LISZBINSKI, B. B. **As práticas contábeis relativas à mensuração e evidenciação dos estoques em empresas industriais do Mercosul e comunidade andina estão convergentes com a norma do IASB?.** Revista Contemporânea de Contabilidade, v. 10, n. 21, 2013.
- THUMMALAPALLI, R. **A Methodology to evaluate obsolete inventory in health care.** University of Nebraska – Lincoln, 2010.
- TRIPATHI, R.; MISHRA, S. **Inventory model with inventory-dependent demand for deteriorating items in a single warehouse system.** Uncertain Supply Chain Management, v. 2, n. 4, p. 209-218, 2014.
- VALLIATHAL, M.; UTHAYAKUMAR, R. **The production-inventory problem for ameliorating/deteriorating items with non-linear shortage cost under inflation and time discounting.** Applied Mathematical Sciences, v. 4, n. 6, p. 289-304, 2010.
- VAN DONK, D. P.; VAN DER VAART, T. **A case of shared resources, uncertainty and supply chain integration in the process industry.** International Journal of Production Economics, 96(1), 97-108, 2005.
- VAN JAARVELD, W.; DEKKER, R. **Estimating obsolescence risk from demand data to enhance inventory control - A case study.** International Journal of Production Economics, 133(1), 423-431, 2011.
- VEENSTRA, C. P.; DEY, E. L.; HERRIN, G. D. **Is Modeling of Freshman Engineering Success Different from Modeling of Non-Engineering Success?.** Journal of Engineering Education, v. 97, n. 4, p. 467-479, 2008.
- VICINI, L.; SOUZA, A. M. **Análise multivariada da teoria à prática.** Santa Maria: UFSM, CCNE, 2005.
- VIJI, G.; KARTHIKEYAN, K. **An economic production quantity model for three levels of production with Weibull distribution deterioration and shortage.** Ain Shams Engineering Journal, 2016.

WANKE, P. **Metodologia para gestão de estoques de peças de reposição**: um estudo de caso em empresa brasileira. *Revista Tecnológica*, 60-65, 2005.

WESTERMAN, W. **Working capital management programs**: Yesterday, today, tomorrow. *Journal of Modern Accounting and Auditing*, 11(4), 210-217, 2015.

WHYBARK, D. Clay. **Issues in managing disaster relief inventories**. *International Journal of Production Economics*, v. 108, n. 1-2, p. 228-235, 2007.

WILD, T. **Best practice in inventory management**. Routledge, 2007.

WILTBANK, R.; DEW, N.; READ, S.; SARASVATHY, S. D. **What to do next? The case for non-predictive strategy**. *Strategic Management Journal*, 27(10), 981-998, 2006.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. **PLS-regression**: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, 58(2), 109-130, 2001.

WONG, C. Y.; ARLBJØRN, J. S.; HVOLBY, H. H.; JOHANSEN, J. **Assessing responsiveness of a volatile and seasonal supply chain**: A case study. *International Journal of Production Economics*, 104(2), 709-721, 2006.

WU, J. Z. **Inventory write-down prediction for semiconductor manufacturing considering inventory age, accounting principle, and product structure with real settings**. *Computers & Industrial Engineering*, 65(1), 128-136, 2013.

WU, W. W. **Beyond business failure prediction**. *Expert Systems with Applications*, 37(3), 2371-2376, 2010.

XIA, D.; CHEN, B. **A comprehensive decision-making model for risk management of supply chain**. *Expert Systems with Applications*, 38(5), 4957-4966, 2011.

XU, P.; BROCK, G. N.; PARRISH, R. S. **Modified linear discriminant analysis approaches for classification of high-dimensional microarray data**. *Computational Statistics & Data Analysis*, 53(5), 1674-1687, 2009.

YANG, Y.; WILLIAMS, E. **Logistic model-based forecast of sales and generation of obsolete computers in the US**. *Technological Forecasting and Social Change*, 76(8), 1105-1114, 2009.

YAO, F.; MÜLLER, H. G.; WANG, J. L. **Functional linear regression analysis for longitudinal data**. *The Annals of Statistics*, v. 33, n. 6, p. 2873-2903, 2005.

YE, J. **Least squares linear discriminant analysis**. In: *Proceedings of the 24<sup>th</sup> international conference on Machine learning*. ACM, 2007. p. 1087-1093.

YIN, R. K. **Estudo de Caso**: Planejamento e Métodos. Bookman Editora, 2015.

YU, L.; LIU, H. **Efficient feature selection via analysis of relevance and redundancy**. *The Journal of Machine Learning Research*, 5, 1205-1224, 2004.

ZHANG, L.; YUAN, Z.; BI, J. **Predicting future quantities of obsolete household appliances in Nanjing by a stock-based model**. *Resources, Conservation and Recycling*, 55(11), 1087-1094, 2011.

ZIMMER, J. **Seleção de variáveis preditivas com base em índices de importância das variáveis e regressão PLS**. Universidade Federal do Rio Grande do Sul, 2012.

ZIMMER, J.; ANZANELLO, M. J. **Um novo método para seleção de variáveis preditivas com base em índices de importância**. *Produção*, São Paulo, 24, 84-93, 2014.



ZSIDISIN, G. A.; ELLRAM, L. M. **An agency theory investigation of supply risk management.** Journal of supply chain management, v. 39, n. 2, p. 15-27, 2003.

**APÊNDICE A - DADOS PREVISTOS E REALIZADOS DE JUNHO A NOVEMBRO  
DE 2015 PARA AS VARIÁVEIS SELECIONADAS - ESTUDO DE CASO 1**

INVENTÁRIO <180 DIAS (C1)	PERÍODO DA PREVISÃO						
	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15
jun/15	90.325	88.518	88.518	88.518	88.518	88.518	88.518
jul/15	92.022	93.829	91.952	91.952	91.952	91.952	91.952
ago/15	124.419	124.419	125.327	126.907	126.907	126.907	126.907
set/15	133.095	133.095	133.095	131.012	129.102	129.102	129.102
out/15	125.084	125.084	125.084	127.077	129.332	128.348	128.348
nov/15	99.957	99.957	99.957	99.957	99.957	99.122	98.957
dez/15	83.310	83.310	83.310	83.310	83.581	83.581	81.074

PREVISTO

REALIZADO

Tabela 20: Inventário menor do que 180 dias (C1) por período – previsto vs. realizado

Fonte: Dados da empresa

VENDA (C2)	PERÍODO DA PREVISÃO						
	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15
jun/15	36.841	37.577	37.577	37.577	37.577	37.577	37.577
jul/15	36.946	38.102	38.793	38.793	38.793	38.793	38.793
ago/15	61.608	61.608	62.126	62.840	62.840	62.840	62.840
set/15	100.428	100.428	100.428	100.203	99.424	99.424	99.424
out/15	119.753	119.753	119.753	120.757	115.825	114.719	114.719
nov/15	132.520	132.520	132.520	132.520	130.850	126.521	125.616
dez/15	114.219	114.219	112.187	112.187	109.943	107.744	106.667

PREVISTO

REALIZADO

Tabela 21: Venda (C2) por período – previsto vs. realizado

Fonte: Dados da empresa

DEVOLUÇÕES (C4)	PERÍODO DA PREVISÃO						
	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15
jun/15	2.165	2.317	2.317	2.317	2.317	2.317	2.317
jul/15	4.747	4.699	4.887	4.887	4.887	4.887	4.887
ago/15	4.000	4.000	4.200	4.158	4.158	4.158	4.158
set/15	4.000	4.000	4.200	4.200	4.326	4.326	4.326
out/15	4.000	4.000	4.200	4.200	4.200	4.116	4.116
nov/15	4.000	4.000	4.200	4.200	4.200	4.300	4.494
dez/15	4.000	4.000	4.200	4.200	4.200	4.400	4.500

PREVISTO

REALIZADO

Tabela 22: Devoluções (C4) por período – previsto vs. realizado

Fonte: Dados da empresa

FIFO (C5)	PERÍODO DA PREVISÃO						
	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15
jun/15	0,78	0,79	0,79	0,79	0,79	0,79	0,79
jul/15	0,82	0,80	0,79	0,79	0,79	0,79	0,79
ago/15	0,84	0,84	0,84	0,82	0,82	0,82	0,82
set/15	0,83	0,83	0,83	0,83	0,80	0,80	0,80
out/15	0,85	0,84	0,84	0,83	0,83	0,79	0,79
nov/15	0,84	0,84	0,84	0,83	0,83	0,83	0,83
dez/15	0,84	0,84	0,84	0,84	0,84	0,83	0,83

PREVISTO

REALIZADO

Tabela 23: Performance do FIFO (C5) por período – previsto vs. realizado

Fonte: Dados da empresa

**APÊNDICE B - DADOS PREVISTOS E REALIZADOS DE MAIO A OUTUBRO DE  
2017 PARA AS VARIÁVEIS SELECIONADAS - ESTUDO DE CASO 2**

VENDA (X1)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	2.950.000	2.771.052	2.771.052	2.771.052	2.771.052	2.771.052	2.771.052	2.771.052
jun/17	3.350.000	3.350.000	3.326.301	3.326.301	3.326.301	3.326.301	3.326.301	3.326.301
jul/17	3.500.000	3.500.000	3.500.000	3.495.034	3.495.034	3.495.034	3.495.034	3.495.034
ago/17	3.600.000	3.600.000	3.600.000	3.600.000	4.474.310	4.474.310	4.474.310	4.474.310
set/17	3.700.000	3.700.000	3.700.000	3.700.000	3.700.000	3.949.975	3.949.975	3.949.975
out/17	5.500.000	5.500.000	5.500.000	5.500.000	5.500.000	5.300.000	6.264.781	6.264.781
nov/17	4.500.000	4.500.000	4.500.000	4.500.000	4.500.000	4.500.000	ND	ND
dez/17	2.400.000	2.400.000	2.400.000	2.400.000	2.400.000	2.400.000	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 24: Venda (X1) por período – previsto vs. realizado

Fonte: Dados da empresa

CPV (X2)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	1.197.864	1.131.459	1.131.459	1.131.459	1.131.459	1.131.459	1.131.459	1.131.459
jun/17	1.397.718	1.407.000	1.420.525	1.420.525	1.420.525	1.420.525	1.420.525	1.420.525
jul/17	1.458.449	1.458.449	1.458.449	1.373.734	1.373.734	1.373.734	1.373.734	1.373.734
ago/17	1.482.234	1.482.234	1.482.234	1.482.234	1.834.940	1.834.940	1.834.940	1.834.940
set/17	1.398.612	1.398.612	1.398.612	1.398.612	1.398.612	1.515.586	1.515.586	1.515.586
out/17	2.179.858	2.179.858	2.179.858	2.179.858	2.179.858	2.179.858	2.338.033	2.338.033
nov/17	1.798.234	1.798.234	1.798.234	1.798.234	1.798.234	1.798.234	ND	ND
dez/17	1.035.620	1.035.620	1.035.620	1.035.620	1.035.620	1.035.620	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 25: CPV (X2) por período – previsto vs. realizado

Fonte: Dados da empresa

COMPRAS (X3)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	779.980	1.240.991	1.240.991	1.240.991	1.240.991	1.240.991	1.240.991	1.240.991
jun/17	885.740	885.740	746.518	746.518	746.518	746.518	746.518	746.518
jul/17	925.400	925.400	925.400	787.591	787.591	787.591	787.591	787.591
ago/17	951.840	951.840	951.840	951.840	1.136.716	1.136.716	1.136.716	1.136.716
set/17	1.017.500	1.017.500	1.017.500	1.017.500	1.017.500	1.747.376	1.747.376	1.747.376
out/17	1.932.150	1.932.150	1.932.150	1.932.150	1.932.150	1.932.150	1.157.686	1.157.686
nov/17	1.254.600	1.254.600	1.254.600	1.254.600	1.254.600	1.254.600	ND	ND
dez/17	652.320	652.320	652.320	652.320	652.320	652.320	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 26: Compra de matérias primas (X3) por período – previsto vs. realizado

Fonte: Dados da empresa

INVENTÁRIO MAT. PRIMA (X4)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	1.637.840	1.723.176	1.723.176	1.723.176	1.723.176	1.723.176	1.723.176	1.723.176
jun/17	1.859.920	1.859.920	1.876.130	1.876.130	1.876.130	1.876.130	1.876.130	1.876.130
jul/17	1.943.200	1.943.200	1.943.200	2.173.563	2.173.563	2.173.563	2.173.563	2.173.563
ago/17	1.998.720	1.998.720	1.998.720	1.998.720	2.104.102	2.104.102	2.104.102	2.104.102
set/17	2.183.000	2.183.000	2.183.000	2.183.000	2.183.000	1.966.984	1.966.984	1.966.984
out/17	3.520.000	3.520.000	3.520.000	3.520.000	3.520.000	3.520.000	1.928.614	1.928.614
nov/17	2.498.400	2.498.400	2.498.400	2.498.400	2.498.400	2.498.400	ND	ND
dez/17	1.403.821	1.403.821	1.403.821	1.403.821	1.403.821	1.403.821	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 27: Inventário de matérias primas (X4) por período – previsto vs. realizado

Fonte: Dados da empresa

INVENTÁRIO PROD. ACAB. (X5)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	2.940.265	4.312.047	4.312.047	4.312.047	4.312.047	4.312.047	4.312.047	4.312.047
jun/17	3.338.945	3.338.945	4.070.037	4.070.037	4.070.037	4.070.037	4.070.037	4.070.037
jul/17	3.488.450	3.488.450	3.488.450	3.941.459	3.941.459	3.941.459	3.941.459	3.941.459
ago/17	3.588.120	3.588.120	3.588.120	3.588.120	3.480.277	3.480.277	3.480.277	3.480.277
set/17	3.687.790	3.687.790	3.687.790	3.687.790	3.687.790	3.388.173	3.388.173	3.388.173
out/17	5.498.900	5.498.900	5.498.900	5.498.900	5.498.900	5.498.900	2.830.778	2.830.778
nov/17	4.485.150	4.485.150	4.485.150	4.485.150	4.485.150	4.485.150	ND	ND
dez/17	2.399.657	2.399.657	2.399.657	2.399.657	2.399.657	2.399.657	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 28: Inventário de produtos acabados (X5) por período – previsto vs. realizado  
Fonte: Dados da empresa

CONSUMO MAT. PRIMA (X6)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	452.220	347.722	347.722	347.722	347.722	347.722	347.722	347.722
jun/17	533.596	533.596	186.364	186.364	186.364	186.364	186.364	186.364
jul/17	535.163	535.163	535.163	463.139	463.139	463.139	463.139	463.139
ago/17	503.489	503.489	503.489	503.489	420.494	420.494	420.494	420.494
set/17	448.601	448.601	448.601	448.601	448.601	593.864	593.864	593.864
out/17	704.144	704.144	704.144	704.144	704.144	704.144	627.655	627.655
nov/17	566.925	566.925	566.925	566.925	566.925	566.925	ND	ND
dez/17	339.576	339.576	339.576	339.576	339.576	339.576	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 29: Consumo de matérias primas (X6) por período – previsto vs. realizado  
Fonte: Dados da empresa

PRODUTOS PRONTOS (X7)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	1.332.590	1.304.300	1.304.300	1.304.300	1.304.300	1.304.300	1.304.300	1.304.300
jun/17	1.540.839	1.540.839	1.065.095	1.065.095	1.065.095	1.065.095	1.065.095	1.065.095
jul/17	1.603.675	1.603.675	1.603.675	1.383.376	1.383.376	1.383.376	1.383.376	1.383.376
ago/17	1.570.608	1.570.608	1.570.608	1.570.608	1.666.838	1.666.838	1.666.838	1.666.838
set/17	1.557.657	1.557.657	1.557.657	1.557.657	1.557.657	1.790.769	1.790.769	1.790.769
out/17	2.088.410	2.088.410	2.088.410	2.088.410	2.088.410	2.088.410	1.809.781	1.809.781
nov/17	1.749.311	1.749.311	1.749.311	1.749.311	1.749.311	1.749.311	ND	ND
dez/17	870.895	870.895	870.895	870.895	870.895	870.895	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 30: Produtos prontos (X7) por período – previsto vs. realizado  
Fonte: Dados da empresa

VOLUME PRODUÇÃO (X8)	PERÍODO DA PREVISÃO							
	mai/17	jun/17	jul/17	ago/17	set/17	out/17	nov/17	dez/17
mai/17	3.800	3.812	3.812	3.812	3.812	3.812	3.812	3.812
jun/17	3.800	3.800	2.552	2.552	2.552	2.552	2.552	2.552
jul/17	4.100	4.100	4.100	4.027	4.027	4.027	4.027	4.027
ago/17	4.100	4.100	4.100	4.100	4.386	4.386	4.386	4.386
set/17	3.800	3.800	3.800	3.800	3.800	3.895	3.895	3.895
out/17	4.300	4.300	4.300	4.300	4.300	4.300	4.193	4.193
nov/17	4.100	4.100	4.100	4.100	4.100	4.100	ND	ND
dez/17	1.800	1.800	1.800	1.800	1.800	1.800	ND	ND

PREVISTO REALIZADO ND DADO NÃO DISPONÍVEL

Tabela 31: Volume de produção (X8) por período – previsto vs. realizado  
Fonte: Dados da empresa