

UNIVERSIDADE DO VALE DO RIO DOS SINOS – UNISINOS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO E
SISTEMAS
NÍVEL MESTRADO

TIMÓTEO ANDRÉ STÜKER

MODELO PARA ATUALIZAÇÃO DA PREVISÃO DE DEMANDA EM CADEIA DE
SUPRIMENTOS DE MODA RÁPIDA NA INDÚSTRIA CALÇADISTA

São Leopoldo
2014

TIMÓTEO ANDRÉ STÜKER

**MODELO PARA ATUALIZAÇÃO DA PREVISÃO DE DEMANDA EM CADEIA DE
SUPRIMENTOS DE MODA RÁPIDA NA INDÚSTRIA CALÇADISTA**

Dissertação apresentada à Universidade do Vale do Rio dos Sinos - Unisinos, como requisito parcial para a obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: Prof. Dr. Miguel Afonso Sellitto

São Leopoldo

2014

S934m Stüker, Timóteo André.
Modelo para atualização da previsão de demanda em cadeia de suprimentos de moda rápida na indústria calçadista / Timóteo André Stüker. – 2014.
170 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, 2014.
"Orientador: Prof. Dr. Miguel Afonso Sellitto."

1. Engenharia de produção. 2. Administração da produção. 3. Canais de distribuição. 4. Calçados – Indústria. 5. Moda – Comercialização. 6. Controle de estoque. I. Título.

CDU 658.5

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecário: Flávio Nunes – CRB 10/1298)

TIMÓTEO ANDRÉ STÜKER

**MODELO PARA ATUALIZAÇÃO DA PREVISÃO DE DEMANDA EM CADEIA DE
SUPRIMENTOS DE MODA RÁPIDA NA INDÚSTRIA CALÇADISTA**

Dissertação apresentada à Universidade do Vale do Rio dos Sinos – Unisinos, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Aprovado em

BANCA EXAMINADORA

Presidente: Dr. Miguel Afonso Sellitto - UNISINOS

Membro: Dra. Maria Auxiliadora Cannarozzo Tinoco - UFRGS

Membro: Dr. André Luis Korzenowski – UNISINOS

Membro: Dr. Daniel Pacheco Lacerda – UNISINOS

AGRADECIMENTOS

Respirar é dom de Deus. Viver é uma dádiva. Reconhecer a presença d'Ele em todos os momentos é um passo para a gratidão. Sem Deus nada posso fazer. Sem Jesus, não poderia conhecê-lo nem chegar a Ele. Por graça somos salvos. E reconheço a mão de Deus em todos os momentos de minha vida, também no mestrado e com certeza não somente nele. Por isso, sou grato.

À minha esposa Simone. Compreensão, companheirismo, suporte, paciência, amor, alegria, conforto, ouvidos, conselhos... Sabes que nosso esforço e sacrifícios no mestrado foram para o futuro de nossa família.

Aos meus pais, Miranda e Daniel. Talvez vocês tenham me ensinado sem palavras que saber é um valor por si só. Não se mede em dinheiro. Que todas as escolhas exigem sacrifícios. E que a maioria das recompensas desses sacrifícios não são visíveis, mas estão lá.

Ao amigo, professor e orientador Sellitto. Obrigado por ter aceitado o desafio de me orientar no meio do caminho. Por me ajudar a olhar para frente, a trazer um objetivo ao trabalho quando ele era só “viagem”. E por corrigir o rumo nos momentos certos, mostrando quando era necessário mais e quando era suficiente. Ainda não teria terminado o trabalho se não fossem tuas contribuições e teu conhecimento. Obrigado pela confiança que tiveste no meu trabalho.

Ao amigo, professor e tutor Gian. Tive confiança de que o mestrado seria a coisa certa a fazer depois que conversamos, ainda antes da prova de seleção. Obrigado por me ajudares a entender as limitações e as oportunidades do mercado calçadista.

Aos demais professores do PPGEPS, obrigado pelas lições ao longo de toda a caminhada.

Aos colegas do mestrado, obrigado pela parceria para encarar os desafios. Destaco os colegas Fábio Murakami, Eron Vaz, Vagner Mâncio, Fabrício Eidelwein, Guilherme Trapp. Artigos, trabalhos, conversas, discussões, ideias... momentos memoráveis! Em especial aos colegas e amigos Mário Lütkemeyer e Carlos Trento. Mário velho de guerra da graduação, parceiro,

obrigado pela disponibilidade de sempre. Trento, obrigado pela parceria nos artigos e trabalhos, pela paciência com o guri novo e com minhas muitas ideias, a minoria boas.

Aos amigos Roger, Andrei, Mannu, Jorginho e Felipe pelas ideias e informações.

Á rádio online christianrock.net. Acompanhou muitos momentos dos artigos e da dissertação.

RESUMO

Para produtos de moda, a demanda é de difícil previsão por modelos lineares ou polinomiais e o ciclo de vida dos produtos é curto. Os varejistas são obrigados a tomarem as decisões de sortimento de produtos e quantidades de compra e estoques bem antes da época da venda, quando apenas informações limitadas e imprecisas estão disponíveis. As decisões são tomadas basicamente confiando em dados qualitativos e questões subjetivas. Os erros na previsão da demanda associados a esse modelo de tomada de decisão se aproxima de 50%. No entanto, as previsões de demanda podem ser melhoradas atualizando as previsões com base nas vendas iniciais. Nesse contexto, o objetivo do presente trabalho é propor um modelo de previsão de demanda baseado no aprendizado com as vendas iniciais para uma cadeia de suprimentos de um varejista de calçados. O modelo foi aplicado em uma rede de varejo calçadista brasileira, na coleção de Verão 2013/2014. O modelo de previsão de demanda foi proposto em duas etapas: (i) a primeira que utilizou dados históricos de vendas agregados por subgrupo de produtos, por loja; e (ii) a segunda que utilizou dados das vendas iniciais para desagregar a previsão por subgrupo na previsão por produtos e cores. Para gerar a previsão de longo prazo foi utilizado o modelo logístico. A Razão de Incremento Semanal (RIS), que é a previsão de vendas semanal por subgrupo dividida pela quantidade de produtos vendidos, foi utilizada como dados de entrada para decompor a previsão em produtos e cores. Além dessa informação, são entradas a quantidade vendida na primeira semana e a quantidade de produtos em estoque. A partir da modificação do cálculo da cobertura de estoques para incluir o RIS, tem-se a previsão de demanda atualizada. A previsão também considera a demanda de substituição e a quebra de grade. Os resultados encontrados demonstraram que o modelo de previsão de demanda atualizado com os dados de vendas obteve desempenho superior ao modelo de previsão original. O modelo de previsão de longo prazo se mostrou adequado para dois dos três subgrupos de produtos analisados. As métricas para medição do desempenho preditivo do modelo utilizadas foram o APE (*absolute percentual errors* ou erro percentual absoluto) e o MAPE* (média absoluta percentual dos erros ajustada). Foram considerados dois horizontes de previsão, seis e oito semanas. O desempenho do modelo conforme a métrica APE para seis semanas de horizonte de previsão foi de 55,199 para o modelo e de 207,511 para o modelo de previsão original. Já para oito semanas de horizonte de previsão foi de 51,232 para o modelo e de 93,212 para o modelo de previsão original. Conforme a métrica MAPE* para seis semanas de horizonte de previsão, o modelo apresentou resultados de 87,598 e o modelo de previsão original apresentou 239,777. E para oito semanas de horizonte de previsão o resultado foi de 88,454 para o modelo e de 167,515 para o modelo de previsão original. Como o modelo foi aplicado somente a um caso, o mesmo não pode ser considerado como validado. Não se pode esperar que os mesmos resultados sejam encontrados em casos diferentes.

Palavras-chave: Gestão da Cadeia de Suprimentos. Varejo. Varejo calçadista. Previsão de Demanda. Gestão de estoques. Moda rápida.

ABSTRACT

For fashion products, the demand is very unpredictable and life cycle of products is short. Retailers are required to make decisions in the assortment and quantities of purchases and inventory a long time before the time of sale, when only limited and inaccurate information is available. Decisions are made relying primarily on qualitative data and subjective issues. Errors in demand forecast associated with this model of decision-making can approach 50%. However, demand forecasts can be improved by updating the predictions based on early sales. In this context, the aim of this work is to propose a demand forecast model based on learning with early sales for a footwear retailer supply chain. The model was applied in a Brazilian footwear retailer in the 2013/2014 Summer Collection. The demand forecasting model was proposed in two stages: (i) the first stage that used historical data aggregated by subgroup, considering product sales per store; and (ii) the second stage that used data from early sales to disaggregate the demand forecast into products and colors. To generate long-term forecast the logistic model was used. The Weekly Increment Proportion (WIP), which is the weekly demand forecast per subgroup divided by the number of products sold, was used as input data to decompose the demand forecast into products and colors. In addition to this information, the other entries are the quantity sold in the first week and the quantity of products in stock. Modifying the inventory turnover calculation to include WIP, we have the updated demand forecast. The forecast also considers the substitution demand and broken grade. The results demonstrated that the demand forecast model based on learning with early sales obtained higher results than original demand forecast model. The long-term forecast model was adequate for two of the three product subgroups analyzed. The metrics for measuring the predictive performance of the model used were APE (absolute percentual errors) and the MAPE* (adjusted mean absolute percentage error). Two forecast horizons were considered, six and eight weeks. The model performance according to the metric APE forecasting six weeks was 55,199 for the model and 207,511 for the original model prediction. Forecasting eight weeks it was 51,232 for the model and 93.212 for the original model prediction. According to the metric MAPE* forecasting six weeks, the model presented a result of 87.598 and the original model presented 239.777. And forecasting eight weeks the result was 88.454 for the model and 167.515 for the original model prediction. As the model was applied to only one case, it cannot be considered validated. The same results are not expected in different cases.

Keywords: Supply Chain Management. Retailing. Footwear retailing. Forecasting. Inventory Management. Fast Fashion.

LISTA DE FIGURAS

Figura 1 – Relações entre os Fatores Críticos de Sucesso.....	28
Figura 2 - Etapas da previsão de demanda	36
Figura 3 – Métodos de Previsão de Demanda	36
Figura 4 – Características de séries temporais.....	39
Quadro 1 – Resumo dos principais modelos de previsão de demanda propostos para o varejo desde o ano 2000.	54
Figura 5 – Método de trabalho.	56
Figura 6 – Modelo conceitual.....	60
Figura 7 – Metodologia do modelo de previsão de demanda.....	71

LISTA DE TABELAS

Tabela 1 – Número de ocorrências de trabalhos nas bases de dados	14
Tabela 2 – Indicadores de produção, emprego, empresas e consumo da indústria calçadista no Brasil.....	14
Tabela 3 – Importações de calçados e partes de calçados para o Brasil.....	15
Tabela 4 – Exportações de calçados do Brasil e do RS.....	15
Tabela 5 – Descrição das variáveis utilizadas para análise de aglomerados	66
Tabela 6 – Coeficientes arbitrados para ponderação da média da Previsão de Longo Prazo...	68
Tabela 7 – Previsão de vendas simples do produto RT 0197 cor acqua	74
Tabela 8 – Verificação de estoque na previsão do produto RT 0194 cor bronze.....	75
Tabela 9 – Demanda de substituição na previsão do produto RT 0194 cor preta.....	77
Tabela 10 – Quebra de grade e modelo final na previsão do produto RT 0194 cor preta.....	79
Tabela 11 – Valores das variáveis utilizadas para análise de aglomerados.....	83
Tabela 12 – Análise de Correlação entre variáveis utilizadas para análise de aglomerados....	84
Tabela 13 – Variáveis utilizadas para a segunda análise de aglomerados.....	85
Tabela 14 – Análise de Correlação entre variáveis utilizadas para a segunda análise de aglomerados.....	86
Tabela 15 – Resultados da análise de aglomerados.....	87
Tabela 16 – Significância dos resultados da análise de aglomerados após teste ANOVA	89
Tabela 17 – Parâmetros do modelo logístico e percentuais para semana 26.....	91
Tabela 18 – Número de modelos vendidos por semana do subgrupo de Rasteiras – Loja 7 ...	97
Tabela 19 – Razão de incremento Semanal Prevista e Realizada para subgrupo de Rasteiras 2013 – Loja 7.....	98
Tabela 20 – Previsão de vendas para a semana 5 – Loja 7.....	100
Tabela 21 – Comparação entre a diferença das vendas das Lojas 4 e 6 em 2013	104
Tabela 22 – Comparação entre a alternância de modelos de previsão das Lojas 4 e 6 em 2013	105
Tabela 23 – Medidas de desempenho preditivo para o modelo de longo prazo.....	107
Tabela 24 – Valores totais previstos e realizados para o modelo de longo prazo para 2013 .	107
Tabela 25 – Resumo das variáveis e restrições da otimização realizada.....	109
Tabela 26 – Coeficientes obtidos pelo Solver para previsão de longo prazo.....	109
Tabela 27 – Medidas de desempenho preditivo para o modelo de longo prazo com coeficientes do Solver.....	110
Tabela 28 – Resumo das medidas de desempenho preditivo para o modelo de curto prazo..	111
Tabela 29 – Medidas de desempenho preditivo ajustadas para modelos com comportamento não conforme	117
Tabela 30 – Resumo das medidas de desempenho preditivo ajustadas para modelos com comportamento não conforme	119
Tabela 31 – Análise do coeficiente alfa.....	119
Tabela 32 – Testes Post Hoc da análise do coeficiente alfa	120
Tabela 33 – Análise focada do coeficiente alfa.....	121
Tabela 34 – Análise por semana do coeficiente alfa – Semanas 5 e 10	121
Tabela 35 – Análise por semana do coeficiente alfa – Semanas 14 e 19	122
Tabela 36 – Análise do coeficiente beta.....	123
Tabela 37 – Análise do coeficiente gama.....	124
Tabela 38 – Análise do coeficiente gama aumentado	125

SUMÁRIO

1 INTRODUÇÃO	11
1.1 CONSIDERAÇÕES INICIAIS	11
1.2 JUSTIFICATIVA E RELEVÂNCIA	13
1.3 DEFINIÇÃO DO PROBLEMA	19
1.4 OBJETIVOS DA PESQUISA	21
1.5 DELIMITAÇÕES DO TRABALHO	21
1.6 ESTRUTURA DO TRABALHO	22
2 REVISÃO BIBLIOGRÁFICA	23
2.1 VAREJO DE MODA	23
2.1.1 Decisões operacionais para gestão da cadeia de suprimentos pelo varejo	24
2.1.2 Fatores críticos de sucesso para o varejo	27
2.1.3 Estratégias de Gestão de Operações do Varejo de Moda	29
2.2 MODA RÁPIDA (<i>FAST FASHION</i>)	33
2.3 PREVISÃO DE DEMANDA	35
2.3.1 Métodos de Previsão	36
2.3.2 Métodos Qualitativos	37
2.3.3 Métodos Quantitativos	38
2.3.4 Séries Temporais	38
2.3.5 Modelos Causais	41
2.3.5.1 Modelo Logístico	42
2.3.6 Métodos com utilização de Inteligência Artificial	43
2.3.7 Medidas de Desempenho Preditivo	45
2.4 PREVISÃO DE DEMANDA NO VAREJO	47
3 MÉTODO	55
3.1 MÉTODO DE PESQUISA	55
3.2 MÉTODO DE TRABALHO	56
3.2.1 Modelo Conceitual	58
3.3 COLETA DOS DADOS	60
3.4 ANÁLISE DOS DADOS	61
4 MODELO DE PREVISÃO DE DEMANDA PROPOSTO	64
4.1 ANÁLISE DE AGLOMERADOS	64
4.2 PREVISÃO DE LONGO PRAZO	67
4.3 PREVISÃO DE CURTO PRAZO	70
4.4 PRESSUPOSTOS DO MODELO	79
4.5 DELIMITAÇÕES DO MODELO	81
5 APLICAÇÃO DO MODELO	83
5.1 ANÁLISE DE AGLOMERADOS	83
5.2 PREVISÃO DE LONGO PRAZO	89
5.3 PREVISÃO DE CURTO PRAZO	99
6 DISCUSSÃO	102
6.1 ANÁLISE DE AGLOMERADOS	102
6.2 PREVISÃO DE LONGO PRAZO	105

6.2.1 Otimização dos coeficientes via Solver do Excel.....	108
6.3 PREVISÃO DE CURTO PRAZO.....	110
6.4 IMPLICAÇÕES GERENCIAIS.....	125
6.4.1 Planejamento de Estoques e Velocidade da Cadeia de Suprimentos	127
6.4.3 Quantidades em estoque e Sortimento de produtos.....	130
6.4.4 Preço e Operação da Loja.....	131
7 CONSIDERAÇÕES FINAIS.....	133
REFERÊNCIAS BIBLIOGRÁFICAS	137
APÊNDICE A	147
APÊNDICE B.....	150
APÊNDICE C	153
APÊNDICE D	156
APÊNDICE E.....	161
APÊNDICE F.....	165

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

Os produtos comercializados no varejo podem ser classificados em produtos básicos e de moda. Produtos básicos apresentam uma demanda relativamente estável e ciclo de vida longo. Essa característica permite que a previsão de demanda e a gestão dos estoques sejam eficazes com a utilização de métodos lineares ou polinomiais, baseados no histórico de vendas. Para produtos de moda, a demanda é de difícil previsão por tais métodos, pois o ciclo de vida dos produtos é mais curto (FISHER; RAJARAM, 2000). O mercado da moda é um sistema aberto complexo, que pode apresentar comportamento caótico, ou seja, pequenas variações em parâmetros de entrada podem causar grandes variações na saída do sistema (CHRISTOPHER et al., 2004). Certo é que o varejo de produtos de moda torna a previsão de demanda e a gestão dos estoques mais difíceis do que em moda básica (FISHER; RAJARAM, 2000).

Os processos de desenvolvimento e de aquisição e os tempos de atravessamento de produção são longos, tanto para roupas como para calçados. Essas características têm criado restrições aos varejistas ao tomarem decisões de quantidade e variedade em estoque (FISHER et al., 2000b). Eles são obrigados a tomarem essas decisões antes da época da venda, quando apenas informações limitadas e imprecisas estão disponíveis. As decisões são tomadas com base em dados qualitativos e questões subjetivas sobre produtos, consumidores e opiniões de quão boa ou ruim será a estação. Os erros na previsão da demanda associados a esse modelo de tomada de decisão aproximam-se de até 50% (FISHER; RAJARAM, 2000; FISHER, 2009). Seguindo esse modelo, após o lançamento da coleção poucos recursos restam para ajustar a oferta à demanda (FISHER et al., 2000b).

Com tais restrições, atingir o desempenho ideal de um varejista – ser capaz de oferecer o produto certo, no local certo, no tempo certo e ao preço certo – torna-se mais difícil (FISHER et al., 2000b). A realidade dos varejistas de moda é que eles frequentemente compram uma quantidade menor do que deveriam de produtos populares e uma quantidade maior do que deveriam de outros produtos, o que resulta em perdas de vendas e margem de lucro. Produtos comprados a mais têm seus preços reduzidos e são vendidos em liquidações. Prova disso é o aumento da quantidade de produtos vendidos em liquidações nos Estados Unidos, passando de cerca de 7% na década de 1970 para cerca de 25% na década de 90 (FISHER, 2009), e para 33% em 1995 (FISHER et al., 2000b).

Recentemente, a indústria da moda tem visto a ascensão do que tem sido chamado de varejistas de *fast-fashion* (moda rápida ou modinha). Varejistas de Moda Rápida são empresas aptas a responderem rapidamente às tendências do mercado. As mesmas lançam novos produtos frequentemente, com ciclo de vida curto (CARO; MARTINEZ-DE-ALBENIZ, 2009). Esses novos produtos refletem as últimas tendências de mercado, sendo os produtos mais desejados pelos clientes (CHOI et al., 2014). Empresas representativas do setor, tais como Zara, H&M, WorldCo, Mango, Benneton, New Look, Top Shop são classificadas dessa maneira (BARNES; LEA-GREENWOOD, 2006; CARO; GALLIEN, 2007, 2010; CARO; MARTINEZ-DE-ALBENIZ, 2009; CHOI et al., 2014; KHAN et al., 2012). Geralmente duas capacidades básicas são identificadas em varejistas de moda rápida: reduzidos tempos de atravessamento de produção e distribuição e desenvolvimento de produtos com “design avançado”, ou seja, acompanhando as tendências da moda (CACHON; SWINNEY, 2011). Em função disso, um elevado número de artigos (produtos) é verificado em comparação com os concorrentes tradicionais.

O movimento que ocorreu na década de 1970 em *Wall Street*, o *Rocket Science Revolution*, está inspirando um movimento semelhante na área do varejo (FISHER, 2009). Esse movimento transformou as decisões de investimento de mais arte que ciência para mais ciência do que arte. O *Rocket Science Retailing*, como chamado no varejo, é possível por existirem as mesmas condições para tal transformação: (a) uma grande quantidade de dados disponíveis, (b) modelos que podem ser aplicados a esses dados, (c) computadores capazes de potencializar a análise dos modelos, e (d) profissionais capacitados a porem em prática essa transformação. O varejo tem se aproximado dessa condição de oferecer muitos dados disponíveis. São quatro os temas importantes em estudo para realizar a gestão da cadeia de suprimentos pelos varejistas: (a) determinar o sortimento de produtos a ser colocado à venda em cada loja, a cada momento no tempo; (b) qual o preço a ser cobrado; (c) quais as quantidades de compra e de estoque desses produtos; e (d) como estimular os funcionários a alcançar a melhor operação ou execução possível da loja (FISHER et al., 2000b; FISHER, 2009).

Assim, para responder ao versátil e volúvel mercado de moda, é preciso possuir um sistema de previsão de vendas adequado (THOMASSEY; FIORDALISO, 2006). Prever a demanda de um ou mais produtos para um determinado período de tempo é um dos temas mais importantes de uma empresa (CHOI et al., 2014; EFENDIGIL et al., 2009). Para a indústria da Moda Rápida esse tema é especialmente importante (CHOI et al., 2014). No entanto, as restrições crescentes (numerosos e novos itens, curto ciclo de vida dos produtos)

fazem com que os modelos de previsão existentes sejam geralmente inadequados ou não utilizados (THOMASSEY; FIORDALISO, 2006). Além disso, para muitos varejistas a previsão de demanda se baseia no instinto de alguns especialistas e não no uso sistemático de dados. Se usadas, essas previsões poderiam ser melhoradas atualizando as previsões com base nas vendas iniciais e com o monitoramento da acuracidade das previsões. A japonesa World Co e a espanhola Zara são empresas que utilizam dados das vendas iniciais para estimar as vendas futuras de diversos produtos, e tem alcançado resultados melhores que a média do mercado. Apenas de 15% a 20% das vendas da Zara são realizadas em liquidações, contra de 30% a 40% da média dos concorrentes europeus (FISHER et al., 2000b).

1.2 JUSTIFICATIVA E RELEVÂNCIA

Um dado que aponta o grau de interesse de pesquisadores e cientistas nos temas abordados é a quantidade de trabalhos publicados de acordo com as palavras-chave pesquisadas. Um resumo da pesquisa realizada em duas bases de dados internacionais é apresentado na Tabela 1. Cada termo foi pesquisado individualmente. A quantidade de trabalhos realizados nas áreas de Previsão de Demanda (*Forecasting*) e Varejo (*Retail*) demonstra o interesse do meio acadêmico em ambos os assuntos. Já a quantidade pequena, porém crescente, de trabalhos sobre Moda Rápida (*Fast Fashion*) demonstra que o assunto é recente e demanda novos trabalhos.

Tabela 1 – Número de ocorrências de trabalhos nas bases de dados

Palavra-chave	Ano	Scopus	ScienceDirect
Forecasting	2014	2871	4760
	2013	16913	9301
	2012	18352	7701
	2011	18631	6976
	2010	20704	5807
Retail	2014	571	3574
	2013	2441	6847
	2012	2326	5702
	2011	2396	5023
	2010	2465	4734
Fast Fashion	2014	3	28
	2013	32	26
	2012	19	27
	2011	26	29
	2010	19	11

Fonte: o autor (2014)

Do ponto de vista social e empresarial, a pesquisa se justifica pela importância da indústria calçadista e do varejo no mercado nacional. A indústria calçadista empregou aproximadamente 337.463 pessoas em janeiro de 2014, sendo 111.009 somente no Rio Grande do Sul (ABICALÇADOS, 2014). A indústria calçadista representa 2,2% do valor adicionado pela indústria de transformação no Brasil (DEPECON, 2013). Por outro lado, o varejo brasileiro cresceu 6,7% em 2011, marcando nove anos de desempenho positivo.

A Tabela 2 apresenta a evolução de alguns indicadores da indústria calçadista entre os anos de 2009 e 2011. A produção em termos de quantidade de pares reduziu na relação 2011/2010. No entanto, o valor de faturamento continuou aumentando. Houve uma redução também no consumo de sapatos no mercado interno.

Tabela 2 – Indicadores de produção, emprego, empresas e consumo da indústria calçadista no Brasil.

DESCRIÇÃO		2009	2010	2011
Produção	Pares (Milhão)	813,6	893,9	819,1
	Valor (Milhão US\$)	9.485,4	12.345,3	12.994,7
Emprego	(Milhares)	319,2	348,7	337,5
Empresas	(Milhares)	7,9	8,2	n/d
Consumo aparente	Pares (Milhão)	717,4	779,6	740,1
Consumo <i>per capita</i>	Pares	3,7	4,1	3,8

Fonte: Abicalçados (2012)

A Tabela 3 apresenta os valores das importações brasileiras de calçados. São apresentados os dados de importações de calçados e a soma de calçados e partes para calçados. As principais origens dos calçados importados pelos brasileiros são o Vietnã e a Indonésia, seguidos da China. A principal origem das partes de calçados importados pelo Brasil é a China. Vietnã e a Indonésia são países para onde não existe a tarifa de *antidumping*, imposta a China (ABICALÇADOS, 2012).

Tabela 3 – Importações de calçados e partes de calçados para o Brasil

DESCRIÇÃO	2012	2013
Calçados		
Valor (US\$)	508.560.399,00	572.376.676,00
Quantidade (Pares)	35.642.595	39.150.544
Preço médio (US\$)	14,27	14,62
Calçados e partes		
Valor (US\$)	613.723.088,00	656.352.616,00
Quantidade (Pares)	54.374.359	55.788.715
Preço médio (US\$)	11,29	11,76

Fonte: Abicalçados (2013a)

As exportações brasileiras de calçados para os anos de 2012 e 2013 são apresentadas na Tabela 4. Também são apresentados os valores exportados pelo estado do Rio Grande do Sul em 2013. Nota-se que 35,34% do valor faturado e 13,41% do total de pares exportados são originados no estado.

Tabela 4 – Exportações de calçados do Brasil e do RS

DESCRIÇÃO	2012	2013	2013 (RS)
Valor (US\$)	1.092.933.890,00	1.095.298.321,00	387.069.827,00
Quantidade (Pares)	113.274.439	122.903.031	16.481.769
Preço médio (US\$)	9,65	8,91	23,48

Fonte: Abicalçados (2013b)

Quanto aos trabalhos realizados sobre os temas relacionados no presente trabalho alguns merecem destaque. Estratégias de resposta rápida à variação de demanda já foram relativamente bem estudadas (CACHON; SWINNEY, 2011), destacando o valor gerado em aproximar a quantidade em estoque da demanda real (CARO; GALLIEN, 2010; CARO; MARTINEZ-DE-ALBENIZ, 2009; FISHER; RAMAN, 1996). Também já foram estudadas a

influência de estratégias de resposta rápida unidas a estratégias de desenvolvimento de produtos com design avançado que estimule no cliente o desejo de comprar o mesmo (CACHON; SWINNEY, 2011), como também foi estudado o impacto do alinhamento do desenvolvimento de produtos com a cadeia de suprimentos em um ambiente de moda rápida (KHAN et al., 2012). Estudando especificamente a indústria da Moda Rápida, Caro e Gallien (2007) estudaram o caso da definição dinâmica do sortimento de produtos aprendendo com a demanda, ou seja, durante a estação de vendas, com foco em encontrar os produtos mais indicados para substituição. Caro e Gallien (2010) também desenvolveram um novo processo operacional para alocar o estoque em uma rede varejista de moda rápida, utilizando o modelo de previsão de demanda desenvolvido por Correa (2007). Esse modelo de previsão considerou a relação entre as vendas iniciais do produto em análise com as vendas iniciais de todos os produtos para definir a quantidade de reposição ideal entre o centro de distribuição e as lojas em análise. Também nessa indústria, foi estudado o impacto do alinhamento do desenvolvimento de produtos com a cadeia de suprimentos (KHAN et al., 2012). Para antever o comportamento da demanda em ambientes de varejo, Caro e Gallien (2012) analisaram experimentos realizados com produtos de teste para estimar os efeitos das intervenções possíveis, como embalagem, disposição na loja e preço. Esse trabalho buscou a otimização da política de liquidação de uma grande rede de varejo de Moda Rápida. Choi et al. (2014) propõe um modelo de previsão de demanda para a indústria de Moda Rápida que utiliza uma combinação de *Extended Extreme Learning Machine* (EELM) e do método Grey.

O trabalho seminal de Fisher e Raman (1996) deu origem a muitos trabalhos considerando as vendas iniciais para aumento da acurácia da previsão de demandas e os ganhos provenientes dessa prática. Fisher e Rajaram (2000) buscaram responder como escolher quais lojas deveriam ser utilizadas para realizar experimentos com as vendas iniciais. Buscaram descobrir como extrapolar os resultados desses experimentos e gerar uma previsão de demanda que abrangesse toda a estação e para todas as lojas da cadeia. Considerando trabalhos que utilizem dados de vendas realizadas para atualizar a previsão de demanda, Hill (1997) propõe a utilização de inferência bayesiana. Já Mostard et al. (2011) propõem utilizar as vendas de *preview* para gerar a previsão de vendas em ambientes onde os tempos de atravessamento sejam longos, ao invés de considerar as vendas iniciais.

Previsões de demanda tem sido alvo de muitos trabalhos. Au et al. (2008) propõe a utilização de redes neurais para previsão de demanda de produtos de moda. Efendigil et al. (2009) propõe uma combinação de redes neurais e lógica difusa para bens de consumo. Thomassey (2010) realizou uma revisão dos métodos de previsão utilizados na indústria têxtil,

e expõe os benefícios da utilização de novos métodos de previsão baseados na utilização de técnicas avançadas de computação, tais como lógica difusa, redes neurais e mineração de dados. No ambiente da moda, o trabalho de Rickman e Cosenza (2007) buscou utilizar mineração de dados (data mining) para identificar tendências dos comentários de blogs de moda para influenciar as previsões de demanda. Aksoy et al. (2012) aplicaram para a indústria têxtil um sistema de previsão semelhante, combinando a capacidade de aprendizado das redes neurais e capacidade de generalização da lógica difusa. Ragg et al. (2002) propuseram a utilização conjunta de redes neurais e aprendizado Bayesiano para a distribuição de jornais na Holanda. Lee et al. (2003) propuseram um modelo que considerou o histórico de vendas, atributos gerais e as pré-vendas para gerar a previsão de vendas de álbuns musicais, utilizando um modelo bayesiano hierárquico. Yelland et al. (2010) descreveram um modelo de previsão que combina previsão por julgamento e estatística, utilizando métodos Bayesianos na Sun Microsystems. Pesquisas junto aos consumidores foram utilizadas como entrada de um modelo que utilizou o teorema de Bayes. A previsão foi atualizada com os dados reais assim que disponíveis para a venda de serviços de internet (LEE et al., 2012). Thomassey e Fiordaliso (2006) propuseram um modelo de previsão baseados em aglomeração de produtos e árvore de decisão para escolha do perfil de vendas a ser adotado para cada produto. Rahman (2008) propõe a previsão de demanda dividida em dois ciclos, o de demanda lenta (prevista por inferência bayesiana) e o ciclo do pico de demanda, para o qual ele propõe um ARIMA combinado com inferência bayesiana. Andrawis et al. (2011) testaram combinações de modelos de previsão utilizando diferentes agregações de tempo para a mesma previsão. Seu trabalho focou o mercado de turismo do Egito, e foram utilizados um modelo para o longo prazo e outro para o curto prazo, obtendo melhores resultados que os modelos utilizados isoladamente. Também considerando previsão de demanda, o trabalho de Zotteri et al. (2005) estuda o impacto do nível de agregação de informação (tempo, local e família de produtos) nos algoritmos de previsão de demanda, bem como se o método de previsão é “de cima para baixo” (considera as previsões por grupos e decompõe para as partes) ou se é de “baixo para cima” (soma as previsões de cada parte, gerando a previsão por grupo).

Já o modelo logístico tem sido utilizado para realizar previsões diversas, não somente de demanda. Miranda e Lima (2010) propõe uma combinação do modelo logístico com o efeito de *Allee* para prever a dinâmica do crescimento populacional. Esse modelo também foi utilizado para prever o crescimento populacional e do Produto Interno Bruto do planeta, buscando antever cenários em nível mundial (MIRANDA; LIMA, 2011). Os trabalhos de Chu et al. (2009) e Wu e Chu (2010) compararam os resultados de previsão da difusão da telefonia

móvel entre os modelos de Gompertz, logístico, de Bass no primeiro, adicionando um modelo de média móvel autorregressivo (ARMA) no segundo, indicando o modelo logístico como o mais apropriado. Gamboa e Otero (2009) compararam os modelos logístico e de Gompertz para o mesmo problema na Colômbia. Yang e Williams (2009) utilizaram o modelo logístico para prever o comportamento das vendas e da obsolescência de computadores pessoais nos Estados Unidos. Já o trabalho de Höök et al. (2010) utilizou o modelo logístico para criar previsões de longo prazo sobre a produção mundial de carvão. Harijan et al. (2011) utilizaram o modelo logístico para prever a difusão da utilização da energia eólica no Paquistão.

Buscando minimizar as perdas provocadas por não possuir em estoque as quantidades demandadas pelo mercado, inúmeros trabalhos tratam a otimização das políticas de estoques e reposição. Fisher et al. (2001) propõe um modelo que identifica o tempo de reposição ótimo, quantifica o benefício de redução do tempo de atravessamento e auxilia na escolha do melhor contrato de reposição. O consumo individual por loja em uma rede de varejo foi considerado por Agrawal e Smith (2013), o que aumenta a acurácia da previsão de demanda e em consequência os lucros. Kok e Fisher (2007) estudaram a estimativa de demanda e a otimização do sortimento de produtos considerando que os consumidores substituirão produtos não encontrados por outros, em um supermercado holandês.

Preencher a lacuna existente entre os modelos científicos, a implementação prática e as restrições do varejo é uma necessidade (HÜBNER; KUHN, 2012) que pode ser buscada por meio de mais trabalhos empíricos (KÖK et al., 2009). A alocação ótima do inventário, considerando o consumo por item e por tamanho continua sendo um problema sem solução, com potencial elevado de retorno para varejistas (AGRAWAL; SMITH, 2013). Correa (2007) criou um modelo de previsão de demanda para a Zara, considerando roupas femininas. O autor sugere como um trabalho futuro a identificação do modelo de previsão de demanda para produtos diferentes do considerado por ele. Também sugere que se pesquise a identificação de um modelo de previsão para o primeiro envio de um novo produto, já que sua pesquisa considerou somente envios de reposições, quando já existe histórico. Também questões relativas à cor, estilo ou design podem influenciar na previsão de demanda e devem ser estudados (CHING-CHIN et al., 2010). Correa (2007) sugere também a utilização de cores e artigos em pesquisas que envolvam a indústria da moda e definições de estoques. A maioria dos modelos utilizados pela academia tem uma visão estática da decisão do sortimento de produto. Kök et al. (2009) sugerem que modificações no sortimento de produtos sejam consideradas em meio à coleção, como acontece na prática. Também sugerem planejamento do sortimento de produtos considerando o aprendizado com as vendas iniciais, bem como

planejamento de sortimento de produtos considerando soluções diferentes para cada loja. Além disso, afirmam que as práticas de planejamento de sortimento de produtos já desenvolvidas e utilizadas pelos varejistas, mais baseadas na arte que na técnica, podem ser tornadas mais robustas pela utilização da grande quantidade de dados disponíveis. Caro e Gallien (2007) afirmam que o estudo da revisão dinâmica do sortimento de produtos é uma área de grande potencial de pesquisa. Também é importante mencionar que nenhum dos softwares oferecidos atualmente no mercado trata os problemas de previsão de demanda considerando o sortimento de produtos (modelo, artigo, cor e tamanho) de um varejista de moda (CORREA, 2007). Thomassey (2010) sugere que se utilizem dois modelos de previsão para ambientes de moda: um de longo prazo (por volta de um ano) e outro de curto prazo (poucas semanas). De um ponto de vista mais abrangente, Brito et al. (2011) sugere que os estudos no varejo no Brasil busquem temas mais relevantes a toda a cadeia de suprimentos, não somente a relação do varejo com os consumidores finais.

1.3 DEFINIÇÃO DO PROBLEMA

O modelo de previsão de demanda de uma rede de varejo calçadista, objeto desse estudo, utiliza principalmente dados qualitativos e subjetivos. Os dados do histórico de vendas são considerados, mas em função das características do varejo de moda, questões subjetivas prevalecem para a tomada de decisão de sortimento de produtos e quantidades de compra e estoque. Esse modelo é o mesmo identificado por Fisher (2009) na maioria dos varejistas. A rede em estudo é formada por 35 lojas monomarcas distribuídas nas regiões Sudeste, Nordeste e Sul do Brasil, bem como outras 20 lojas multimarcas que compram eventualmente produtos da marca. Os fornecedores de produto são de pequeno e médio porte e produzem somente contra pedidos (*make-to-order*), não existindo a prática de manutenção de estoques de produtos prontos na fábrica ou centro de distribuição para reposições rápidas. Também não é comum a reposição de estoques de produtos populares. O volume de itens comercializado pela rede em 2013 foi de aproximadamente 800.000 peças, entre sapato, bolsas e bijuterias. Em 2014 a previsão era de comercializar aproximadamente 1.000.000 de peças, em função do crescimento do número de lojas e do crescimento nas vendas.

Esse comportamento se deve à característica da cadeia de suprimentos: tempos de atravessamento de produção que oscilam em torno de oito semanas, necessidade de produção de lotes com quantidades mínimas, estrutura de compra não preparada para revisão de estoques e reposição de itens com consumo elevado. Além disso, uma opção estratégica da

empresa torna ainda mais complexa a gestão. No que se refere à decisão do sortimento de produtos, é muito semelhante às empresas que praticam moda rápida: durante as coleções, a cada quatro semanas novos produtos são colocados à venda, renovando praticamente todos os produtos em exposição na loja. Essa prática resulta num elevado número de itens comercializados.

Considerando esse cenário em que a empresa oferece um número elevado de itens, como os varejistas de moda rápida, mas sem a capacidade de resposta característica desses sistemas, a incerteza para as tomadas de decisão referentes ao sortimento de produtos a ser ofertado é elevada. Assim como também é elevada a incerteza sobre as quantidades a serem compradas e mantidas em estoque. Assim, as liquidações são inevitáveis. Nos últimos anos, para diminuir o risco inerente, quantidades menores por produto foram compradas. As perdas de vendas de produtos populares são difíceis de serem verificadas. No entanto, sendo a geração de estoques excessivos um problema de maior impacto, existe a tendência de que a decisão quanto a quantidades a serem compradas seja conservadora. Esse comportamento já foi notado em varejistas de moda rápida (CHOI et al., 2010). Nota-se também que as quantidades de compra e estoques consideradas a partir do planejamento confundem-se com as metas de venda da empresa. Dessa forma, o objetivo com a previsão de demanda acaba não sendo atender a demanda real pelo produto, mas sim atender a meta de vendas definida pela estratégia para aquela família de produtos. Já a decisão de sortimento de produtos é feita com base no planejamento de produtos. Mas a revisão do planejamento do sortimento (se o resultado foi o esperado ou não) é feita de maneira intuitiva, sem análise aprofundada dos dados. E não utilizar ferramentas estatísticas para tratar os dados gerados é uma característica comum aos varejistas (FISHER; RAJARAM, 2000).

Apesar de alguns estudos abordarem soluções semelhantes, algumas condições são diferentes. Um exemplo é comparar a rede Zara, que tem fabricação própria, e as soluções empregadas para seus problemas. A condição da empresa estudada, sem fabricação própria, é a mais comum no Brasil, o que aumenta o potencial do modelo em termos de aplicação prática, caso ele seja generalizado em futuros trabalhos. Também cabe ressaltar que apesar de existirem estudos que apontam que Zara e World Co aprendem a respeito do sortimento de produtos de acordo com as vendas iniciais (FISHER et al., 2000b), o método não está detalhado.

A inaptidão em determinar a quantidade ideal de compras e estoques e o sortimento de produtos é uma característica dos mercados de moda. Ao invés de buscar métodos mais eficazes de previsão de demanda, o que se tem buscado são métodos de revisão e atualização

da demanda, ou seja, métodos que buscam aprender com as vendas iniciais e o aumento da agilidade e capacidade de resposta do sistema como um todo. A seguinte questão de pesquisa emerge dessa necessidade: como aprender com as vendas iniciais para revisar e atualizar as previsões de demanda de produtos em uma rede de varejo calçadista?

1.4 OBJETIVOS DA PESQUISA

Os objetivos foram definidos como geral e específicos, sendo que estes últimos representam as metas intermediárias para o alcance do objetivo geral.

O objetivo geral da presente pesquisa é **propor um modelo de previsão de demanda baseado no aprendizado com as vendas iniciais para uma rede de varejo calçadista.**

Os objetivos específicos do trabalho são:

- Determinar o modelo de regressão linear ou não linear mais adequado à previsão de demanda de longo prazo, baseado no grupo de produtos;
- Determinar o método para atualizar a previsão de demanda de curto prazo desagregada em produtos e cores, baseado nas vendas iniciais;
- Medir a acuracidade do modelo proposto, discutindo a viabilidade e as implicações práticas de sua aplicação.

1.5 DELIMITAÇÕES DO TRABALHO

Esta seção apresenta as delimitações do trabalho. Os resultados do trabalho se referem especificamente às redes de varejo calçadistas e suas cadeias de suprimento. Também são delimitados ao caso em questão, sendo que os mesmos não podem ser generalizados. Compete lembrar que o foco de aplicação do método é em redes de varejos calçadistas do tipo “monomarcas” (*Private Label Store Brands*). O modelo proposto não considera a política de compra ou reposição da rede varejista. A análise dos resultados da previsão permitirá que se avaliem alternativas com relação à utilização ou não da política de reposições. Também não é preocupação desse estudo a comparação direta entre modelos de previsão de vendas. O modelo gerado foi confrontado com um modelo de previsão empírico adotado pela empresa, para confirmar a capacidade preditiva mínima.

A previsão de demanda resultante do trabalho realizado está limitada ao ponto de venda, no caso da previsão de curto prazo. No caso da previsão de longo prazo, está

delimitada à agregação dos pontos de venda de toda a rede em análise. A previsão de vendas da fábrica não será considerada. Além disso, a avaliação da previsão de demanda não incorporará métricas qualitativas. E o trabalho não fará uma avaliação econômica entre o custo de não vender e o custo de estocar.

Quando tratar tempo de atravessamento (*lead-time*), o trabalho não irá considerar a capacidade do varejista de captar variações no mercado e introduzi-los em seus produtos (*time-to-market* e *time-to-react*), mas tratará essencialmente o tempo desde o pedido de compra até a realização da entrega na loja (*time-to-serve*) (CHRISTOPHER et al., 2004).

1.6 ESTRUTURA DO TRABALHO

A dissertação está estruturada da seguinte forma:

O capítulo 1 consiste em uma introdução à dissertação, apresentando as considerações iniciais a respeito do tema, justificativa e relevância, a definição do problema, os objetivos da pesquisa, a metodologia, as delimitações e a estrutura do trabalho.

O capítulo 2 apresenta a revisão teórica. Inicialmente, são apresentados: Gestão da Cadeia de Suprimentos, Varejo de moda, Estratégias de Gestão de operações do Varejo de moda e a conceituação de Moda Rápida. Esses temas iniciais buscam contextualizar o ambiente em que a pesquisa será conduzida e um apanhado geral sobre os conceitos e teorias que serão abordados pelo modelo. Posteriormente, o referencial teórico buscará demonstrar os seguintes temas: Previsão de Demanda e os Métodos de previsão de demanda, bem como os aspectos a serem considerados para modelagem de sistemas de previsão de demanda de moda.

O capítulo 3 apresenta a metodologia aplicada para responder a questão de pesquisa. É apresentado o método de trabalho, no qual as etapas a serem cumpridas para alcançar o objetivo do trabalho estão descritas. É apresentada também a metodologia do modelo proposto.

No capítulo 4 é descrita a utilização de dados reais no modelo proposto, da rede varejista cujo contexto é objeto de estudo do presente trabalho.

No capítulo 5 é apresentada a discussão dos resultados encontrados. São considerados o desempenho preditivo, a viabilidade do modelo proposto e as implicações gerenciais da utilização das informações provenientes do aprendizado com as vendas iniciais.

Por fim, o capítulo 6 traz as considerações finais, nas quais os principais resultados do trabalho são revisitados, são discutidas as limitações do trabalho e são apresentadas proposições de futuros trabalhos como continuidade de pesquisa.

2 REVISÃO BIBLIOGRÁFICA

2.1 VAREJO DE MODA

Varejo são todas as atividades que englobam o processo de venda e serviços para atender uma necessidade pessoal do consumidor final (PARENTE, 2000). Levy e Weitz (2004) definem varejo como um conjunto de atividades de negócio que adicionam valor aos produtos e serviços vendidos aos consumidores para seu uso pessoal ou familiar. Qualquer organização que venda para consumidores finais – fabricante, atacadista ou varejista – está fazendo varejo. A maneira como produtos ou serviços são vendidos (pessoalmente, pelo correio, por telefone, por máquinas de venda ou pela internet) ou onde eles são vendidos (em uma loja, na rua, na casa do consumidor) não é importante (KOTLER, 2000).

Os varejistas de moda podem segmentar os produtos em produtos básicos e de moda (FISHER et al., 1994). Produtos básicos têm demanda relativamente estável um longo ciclo de vida, o que torna bastante fácil de prever a demanda e gerenciar o inventário de um determinado produto usando métodos padrão que dependem de um histórico de vendas do produto. Previsão e gestão de estoques são muito mais difíceis de produtos de moda. Sua demanda é altamente imprevisível, e eles têm um curto ciclo de vida - tipicamente apenas alguns meses. Eles são frequentemente comprados apenas uma vez, em um tempo antes do início da temporada de vendas reais, e a decisão de quanto comprar não é baseada em vendas reais do produto, mas apenas no julgamento subjetivo de especialistas e compradores sobre quão bem que eles serão vendidos (FISHER; RAJARAM, 2000).

Fisher et al. (2000b) afirmam que o principal objetivo do varejo é ser capaz de oferecer o produto certo, no lugar certo, no tempo certo e ao preço certo. No entanto, mesmo com a enorme quantidade de dados disponível a respeito de pontos de venda, padrões de compra e preferências dos clientes, muitos varejistas ainda estão distantes de alcançarem esse objetivo. Para que o objetivo do varejo seja alcançado, os autores elencam quatro elementos importantes: (i) dados disponíveis e precisos, (ii) previsão de demanda, (iii) planejamento de estoques baseados no risco e (iv) velocidade da cadeia de suprimentos. Na mesma linha, Mattila (1999) identificou que os fatores críticos de sucesso associados à aquisição de produtos sazonais de moda são: (i) a acuracidade da previsão de demanda, (ii) o *lead-time* do processo, (iii) o composto *offshore* / local da aquisição, e (iv) a composição de compra inicial e reposições.

Fisher (2009) lista algumas características do varejo que tornam a área interessante

para a Gestão de Operações:

- Os varejistas têm objetivos claros, como o crescimento de vendas e margem bruta;
- As decisões que eles precisam tomar influenciam diretamente esses objetivos, como qual o sortimento de produtos a ofertar, em que quantidades e em que os preços;
- Os varejistas estão coletando enormes quantidades de dados de transações de consumo em função da utilização de novas tecnologias aplicadas. Esses dados podem dar aos varejistas a capacidade de entender os consumidores mais profundamente, por meio da análise de o que compram, de seus dados demográficos e até mesmo por meio do processo pelo qual eles decidem o que comprar;
- O ritmo de implementação de novas ideias é muito rápido; e
- Gerenciamento de inventário é uma das coisas mais importantes que um varejista faz, portanto, uma atividade intelectual chave para a gestão de operações.

2.1.1 Decisões operacionais para gestão da cadeia de suprimentos pelo varejo

Os varejistas precisam definir ao menos quatro importantes questões para gerenciarem suas cadeias de suprimento: determinar qual o sortimento de produtos a ser oferecido em cada ponto de venda a cada momento; definir preço; definir quantidades de estoque; e estimular funcionários para a execução das necessidades do negócio (FISHER, 2009).

O sortimento de produtos varejista é definido pelo conjunto de produtos abastecidos em cada loja, em cada ponto no tempo. O objetivo do planejamento do sortimento de produtos é especificar um conjunto que maximize vendas ou margem bruta. Este objetivo está sujeito a várias restrições, tais como orçamento limitado para compra de produtos, espaço de prateleira limitado para apresentação de produtos, e ter pelo menos dois fornecedores para cada tipo de produto. O sortimento de produtos de varejistas exerce influência sobre vendas e margem bruta. Seu planejamento é priorizado por varejistas, consultores e fornecedores de software. No entanto, até a data da pesquisa, nenhuma solução dominante foi encontrada para esse problema (KÖK et al., 2009).

Kök et al. (2009) ainda afirmam que os varejistas se empenham no planejamento do sortimento de produtos porque eles precisam revê-lo periodicamente. Vários fatores exigem que eles hajam dessa maneira, incluindo estações (o sortimento de produtos de outono será diferente do sortimento de produtos da primavera), a introdução de novos produtos e

mudanças nos gostos dos consumidores. Muitos varejistas segmentam o estoque em categorias de SKU's (Stock Keeping Units - Unidades de Manutenção de Estoque). Dentro das categorias, eles costumam segmentar subcategorias ainda antes da segmentação em produtos. A terminologia usada varia. Por exemplo, classe e subclasse podem ser usadas em vez de categoria e subcategoria, mas a prática de agrupar SKU's com atributos semelhantes para fins de planejamento é disseminada. Os varejistas decidem qual é a fração de seu espaço de prateleira e orçamento de compra de produto a ser dedicada para cada categoria subcategoria. O planejamento do sortimento de produtos requer um equilíbrio entre três elementos: o número de diferentes categorias que o varejista irá utilizar (amplitude), o número de SKU's em cada categoria (profundidade), e quanto inventário será estocado de cada SKU, o que obviamente afeta seu estoque (KÖK et al., 2009).

A literatura que explora questões relevantes para a gestão de produtos de moda em cadeias de varejo é significativamente menor que a literatura que trata de outros modelos (AGRAWAL; SMITH, 2009a). São identificados dois modelos para produtos de moda. Um modelo que considera os produtos em estações de venda muito curtas e tempos de atravessamento normalmente maiores que o tamanho da estação de venda. Conseqüentemente, um número limitado de possibilidades (frequentemente uma ou duas) de reposições é possível, com a incerteza da demanda tendendo a crescer. Por outro lado, a outra opção de modelo apresenta um problema de mais difícil solução, já que considera existirem múltiplas localizações, inventário limitado, e mais do que uma oportunidade para reposições. O que também oferece a possibilidade de atualizações de previsão com base nas vendas observadas. Ao comparar o desempenho do sistema sob os diferentes mecanismos, desenvolveram-se conhecimentos sobre a os benefícios resultantes de: (a) utilizar informações sobre a demanda atualizada para modificar os níveis de estoque de lojas individualmente ou o conjunto de lojas que serão abastecidas no meio da estação; e (b) acordos de fornecimento flexíveis que permitam que a quantidade de reabastecimento total possa ser ajustada no meio da estação (AGRAWAL; SMITH, 2009b).

As políticas de preços são, atualmente, um componente fundamental das operações de empresas de manufatura e serviços, provavelmente porque o preço é uma das variáveis mais eficazes a serem manipuladas pelos gestores para encorajar ou desencorajar a demanda no curto prazo. O preço não é importante somente do ponto de vista financeiro, mas também do ponto de vista operacional, já que auxilia a regular o inventário e as pressões de produção. As companhias aéreas e redes de varejo são bons exemplos de indústrias onde a política de precificação dinâmica tem se tornado fator-chave do desempenho das empresas. Os

pesquisadores perceberam que os problemas operacionais clássicos, como capacidade ideal e gestão de inventário, entre muitos outros, não podem ser dissociados das atividades de marketing e, especialmente, das decisões de preço (BITRAN; CALDENTEY, 2003).

A otimização da precificação dinâmica, um ramo da gestão de receitas, investiga o preço como variável-chave de decisão em um ambiente de negócios dinâmico. Em particular, estuda como operacionalizar as decisões de preços, considerando, por exemplo, estoques e seu nível ao longo do tempo (WHANG, 2009). Em termos de aplicações, práticas de precificação dinâmica são particularmente úteis para indústrias com elevados custos iniciais, capacidade perecível, estações de venda curtas, e demandas ao mesmo tempo estocásticas e sensíveis a preços. O problema da gestão de receitas foi enunciado como "vender o produto certo para o cliente certo, na hora certa." Por um lado, os vendedores gostariam de vender seus produtos para os clientes que identificam maior valor nos mesmos, alcançando altas margens. Por outro lado, se esperarem muito tempo para esses clientes aparecerem, eles podem acabar o período de vendas com unidades não vendidas, que poderiam ter sido vendidos a outros clientes (BITRAN; CALDENTEY, 2003).

Um número significativo de clientes deixam as lojas de varejo porque não conseguem encontrar os produtos que procuram. Normalmente dois fatores são apontados para explicar a indisponibilidade de produtos: sortimento de produtos pobre e planejamento de estoque inadequado. Há, no entanto, um terceiro fator, a má execução ou o fracasso em executar um plano operacional. Mesmo quando a aplicação de algoritmos para selecionar a quantidade de alocação adequada e sortimento de produtos adequado para a loja, os clientes de varejo podem ainda assim não encontrarem os produtos. Evidências de problemas de execução ou operação existem em diferentes contextos. Centros de distribuição, empresas de manufatura, empresas de serviços financeiros, empresas de serviços públicos, hospitais e agências governamentais têm enfrentado problemas com produtos extraviados e registros imprecisos. Os custos em função da má execução ou operação da loja nesses contextos, tal como no varejo, demonstram-se substanciais (DEHORATIUS; TON, 2009).

Os efeitos de uma má operação da loja são registros imprecisos de inventário e produtos extraviados (DEHORATIUS; TON, 2009). Em um caso estudado por DeHoratius e Raman (2007), quase todos os produtos verificados fisicamente em auditoria como com estoque zerado foram verificados no sistema como com quantidades disponíveis. O que torna essas faltas invisíveis aos gestores do inventário. DeHoratius e Ton (2009) afirmam que produtos extraviados, sejam eles trocados nas prateleiras ou deixados nos depósitos, geram faltas de estoque se os clientes não são capazes de localizar o produto que procuram. Foram

identificadas três fontes de má execução ou operação: (1) má concepção do processo, (2) um ambiente operacional que torna difícil para os empregados cumprirem com os processos prescritos, e (3) erros de funcionários. Fatores que agravam a ocorrência desses problemas incluem variedade de produtos, níveis de estoque, rotatividade de funcionários, a carga de trabalho e esforço por parte dos empregados (DEHORATIUS; TON, 2009).

2.1.2 Fatores críticos de sucesso para o varejo

Os fatores críticos de sucesso para o varejo são quatro: (i) a acuracidade da previsão de demanda, (ii) o tempo de atravessamento (*lead time*) do processo, (iii) o composto de compra no mercado externo e no mercado interno e (iv) a relação entre compra inicial e reposições (MATTILA et al., 2002; MATTILA, 1999).

O planejamento de compras de varejistas é feito com base na previsão de demanda. A acuracidade da previsão é o principal fator de sucesso para o varejo. No entanto, não existem previsões perfeitas. Os erros geram tanto sobras de produtos, vendidos em liquidações, quanto faltas de produto e vendas perdidas. Assim, a previsão de demanda tem um impacto fundamental no desempenho do varejo (MATTILA, 1999). Como trata de varejo, a acuracidade da previsão sendo discutida é tanto no ponto de venda como na compra total para a coleção.

O tempo de atravessamento desde a realização do pedido de compras até o recebimento dos produtos é a principal causa dos erros de previsão de demanda. Isso porque as decisões de compra precisam ser tomadas antes do início da estação, baseadas na previsão de demanda. Em função dos longos tempos de atravessamento, os estoques precisam ser maiores e o desempenho financeiro da empresa é reduzido. As necessidades de fluxo de caixa também aumentam (MATTILA, 1999). O autor também percebeu que a informação a respeito do comportamento da demanda não aumenta com a aproximação da estação de vendas, já que a previsão de demanda utilizou dados históricos que não mudaram. Assim, reduzir os tempos de atravessamento, mesmo que em meses, mas antes do início da estação de vendas não irá facilitar o planejamento dos estoques, e em consequência melhorar desempenho do varejo. Mas após o início das vendas, a informação é atualizada com qualidade. Então, a acuracidade de uma nova previsão de demanda atualizada com os dados de venda será superior. Se for possível utilizar reposições durante a estação, o desempenho poderá ser melhorado.

O composto de compra no mercado externo e no mercado interno impacta o desempenho do varejo em função do preço de aquisição obtido na compra em países com

preço de mão de obra inferior. Por vezes, a redução do valor é elevada. Por outro lado, a opção por comprar grandes quantidades desses países impacta o tempo de atravessamento, gerando os distúrbios anteriormente citados.

Por fim, a relação entre compra inicial e reposições pode determinar a prática de reposições de estoque com a estação em andamento. Essa estratégia necessita de curtos tempos de atravessamento, mas permite a utilização de atualizações da previsão de demanda com informações das vendas iniciais. A Figura 1 exemplifica a relação entre os fatores críticos de sucesso.

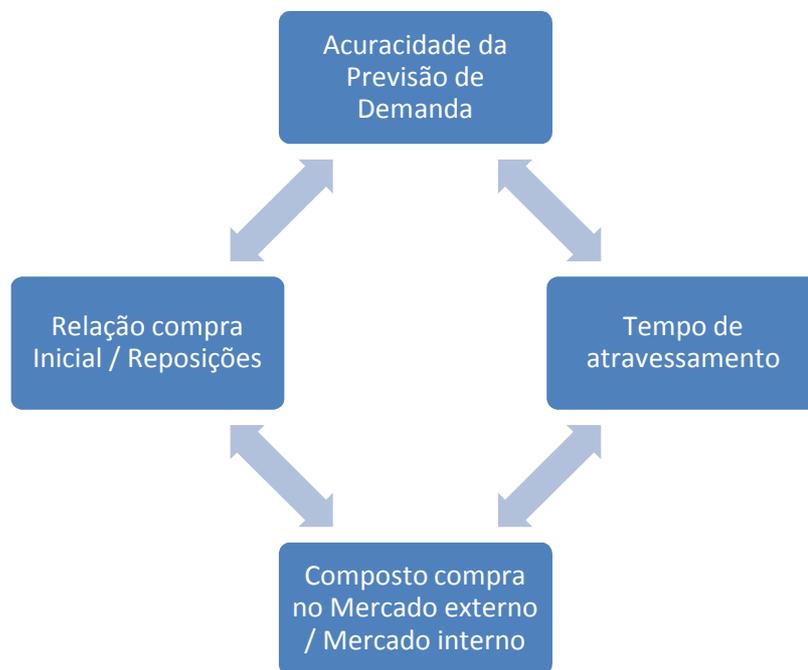


Figura 1 – Relações entre os Fatores Críticos de Sucesso

Fonte: adaptado de Mattila (1999)

Observando-se as relações entre os fatores, percebe-se que existe uma sequência de realimentação entre as relações. Isso porque é necessário aumentar a acuracidade da previsão para se obter sucesso, sendo que a gestão precisa focar as ações no sentido de minimizar o erro da previsão. Além disso, as decisões de compra no mercado interno ou no mercado externo afetam diretamente o tempo de atravessamento. No entanto, quanto maior o tempo de atravessamento, mais distante o objetivo da previsão, e menor a acuracidade da mesma. Por outro lado, se o tempo de atravessamento for curto, é possível utilizar informações de demanda realizada para atualizar a previsão de demanda, atualizando as quantidades em estoque por meio de reposições. O que aumenta a acuracidade da previsão de demanda, já que

o horizonte de previsão é reduzido (MATTILA, 1999).

2.1.3 Estratégias de Gestão de Operações do Varejo de Moda

Atualmente, pode ser notada uma mudança na estratégia da indústria da moda, de centrada no produto para centrada no cliente, (KHAN et al., 2008). A estratégia centrada no produto é feita com base em previsões de demanda estáveis, longos tempos de atravessamento e projetadas para aumento e manutenção da eficiência de produção. Estratégias centradas no cliente tem buscado eliminar as diferenças entre a previsão de demanda e a venda real, capacitando os fornecedores a atenderem a demanda real reduzindo o risco inerente da operação da cadeia de suprimentos (KHAN et al., 2012). Moda é um termo amplo que tipicamente inclui qualquer produto ou mercado em que haja um elemento de estilo e que tenha vida-útil curta (CHRISTOPHER et al., 2004). Os mercados de moda exibem geralmente as seguintes características:

- Ciclos de vida curtos - o produto muitas vezes é efêmero, projetado para capturar a tendência do momento. Conseqüentemente, o período em que será vendável provavelmente será muito curto e sazonal, medido em meses ou até mesmo semanas.
- Alta volatilidade - a demanda por esses produtos é raramente estável ou linear. Pode ser influenciada por variações do tempo (temperatura), filmes ou até mesmo por estrelas pop e jogadores de futebol.
- Baixa previsibilidade - devido à volatilidade da demanda é extremamente difícil prever com precisão a demanda total dentro de um mesmo período, muito menos semana a semana ou a demanda item por item.
- Alto nível de compra por impulso - muitas decisões de compra por parte dos consumidores para esses produtos são feitas no momento da compra. Em outras palavras, o cliente quando confrontado com o produto é estimulado a comprá-lo, daí a necessidade crítica de disponibilidade de produto.

Bruce et al. (2004) afirmam que algumas estratégias têm sido utilizadas para melhorar o desempenho da gestão da cadeia suprimentos na indústria da moda: *Quick Response* e *Accurate Response*, *Demand Chains*, *Lean Supply*, *Agile Supply* e *Leagile Supply*.

Atualmente, a *Quick Response* é reconhecida como uma estratégia de operações

(LOWSON, 2002) e, como tal, atrai considerável interesse para a capacidade da mesma em lidar com a complexidade da logística da indústria da moda. *Quick Response* pode ser definida como: um estado de capacidade de resposta e flexibilidade no qual uma organização procura fornecer uma gama altamente diversificada de produtos e serviços para um cliente na exata quantidade, variedade e qualidade, e na hora certa, lugar e preço, ditada pelo cliente em tempo real. *Quick Response* oferece a capacidade de tomar decisões baseadas em informações da demanda real, no último momento possível, em tempo de garantir que a diversidade de oferta seja maximizada e tempos de atravessamento, despesas, custos e inventário minimizados. *Quick Response* enfatiza a flexibilidade e a velocidade a fim de atender às exigências que mudam constantemente de um mercado altamente competitivo, volátil e dinâmico (LOWSON et al., 1999). *Accurate Response* é uma proposta de previsão de demanda, planejamento e produção que se baseia nas capacidades desenvolvidas pela *Quick Response* na cadeia de suprimentos. Busca elevar o desempenho da cadeia de suprimentos suficientemente para que os fabricantes possam postergar a decisão de produzir até que a previsão de demanda possa ser validada por dados do ponto de venda. Para que essa estratégia alcance o sucesso, é necessário utilizar recursos de tecnologia da informação para que o fluxo de informação seja rápido o suficiente para entregar os produtos eficientemente (HUNTER; VALENTINO, 1995).

Demand Chains é um modelo proposto por De Treville et al. (2004) que buscou analisar o que é prioritário na gestão da cadeia de suprimentos: reduzir tempos de atravessamento ou compartilhar informações. Os resultados indicaram que essa resposta depende de como a cadeia pode ser classificada quanto ao tempo de atravessamento relativo e quanto à qualidade da informação de demanda compartilhada. O tempo de atravessamento é relativo entre ele mesmo e o tempo até a informação sobre a demanda ser informada ao fabricante, podendo ser classificada em: (a) totalmente observada; (b) parcialmente observada; e (c) não observada. Já a informação sobre a demanda compartilhada pode ser: (a) totalmente compartilhada; (b) parcialmente compartilhada; e (c) não compartilhada.

Para entender os demais conceitos, é necessário abordar o conceito de *lean*. Womack e Jones (1996) desenvolveram o conceito de organização enxuta (*lean*). Um grupo de empresas individuais, funcional e legalmente separadas, mas operacionalmente sincronizadas. O foco do *Lean Supply Management* (Gestão da Produção Enxuta) é a eliminação de todas as perdas, incluindo perdas de tempo. *Lean Manufacturing* está ligada ao conceito do Sistema Toyota de Produção (OHNO, 1997). No ocidente, sua aplicação ficou restrita à fábrica, e não foi estendida para outras partes da cadeia de suprimentos, onde grandes quantidades de produto

acabado eram estocadas em antecipação de pedidos de clientes. Apesar da presença de instalações de manufatura enxuta na cadeia de suprimentos, onde tempos de produção foram sendo reduzidos drasticamente, os clientes ainda sofriam atrasos significativos na entrega de suas encomendas (FISHER, 1997). Abernathy et al. (2000) propõem um modelo para uma gestão enxuta da cadeia de abastecimento para a indústria têxtil e de vestuário. Eles argumentam que os varejistas enxutos exigem rápida reposição de produtos e prazos de entrega curtos, e para isso é necessário recursos de tecnologia da informação.

A ideia de agilidade no contexto da gestão da cadeia de suprimentos se concentra em torno de "capacidade de resposta". Cadeias de suprimentos ágeis são mais curtas do que as cadeias de suprimentos convencionais e buscam ser orientadas pela demanda. Cadeias de suprimentos convencionais são baseadas em previsões de demanda e isso implica que elas são baseadas em inventários. Cadeias de suprimentos ágeis são propensas a serem baseadas na informação. Pela sua própria natureza, os mercados de moda são voláteis e difíceis de prever. Daí a necessidade de agilidade. (HARRISON et al., 1999) afirmam que uma cadeia de suprimentos ágil apresenta as seguintes características: é sensível ao mercado - está intimamente ligada às tendências do usuário final; é virtual - se baseia em informações compartilhadas entre todos os parceiros da cadeia de suprimentos; é baseada em rede - ganha flexibilidade, utilizando os pontos fortes de fornecedores especializados; apresenta alinhamento dos processos - tem um elevado grau de interligação dos processos entre os membros da rede. Childerhouse e Towill (2000) argumentam que a adoção dos princípios *Lean* é apropriada para produtos onde a demanda de commodities podem ser previstos e os princípios ágeis são relevantes para produtos inovadores, onde a demanda é imprevisível.

O conceito "*Leagile*" para cadeias de suprimentos propõe uma combinação de abordagens enxutas e ágeis combinadas com um ponto de dissociação ou desacoplamento, para uma gestão ótima da cadeia de suprimentos (HOEK, 2000; MASON-JONES et al., 2000; NAYLOR et al., 1999). Mason-Jones et al. (2000) argumentam que a agilidade deve ser utilizada a jusante e o conceito enxuto será utilizado a montante do ponto de desacoplamento da cadeia de suprimentos. Antes do desacoplamento, o objetivo principal da cadeia é reduzir custo. Após o desacoplamento, o objetivo principal da cadeia passa a ser aumentar a agilidade. Assim, "*leagile*" permite a busca de eficiência e redução de custos no início da cadeia e altos níveis de serviço à jusante, o que é adequado a mercados voláteis.

A Teoria das Restrições (Theory of Constraints – TOC) foi proposta inicialmente pelo físico israelense Eliyahu Goldratt. O conceito básico dessa teoria é que em qualquer sistema existem restrições que limitarão o ganho. Uma restrição é algo que impõe limites para a

empresa performar em relação à sua meta (NOREEN et al., 1996). Para gerenciar a restrição, é preciso identificá-la e subordinar as demais atividades e recursos à restrição. Assim, é possível maximizar o desempenho de restrição e, em consequência, o desempenho da organização. A aplicação da ferramenta tambor, pulmão e corda (TPC) é possível visualizar como ritmo de trabalho flui através de um sistema, determinado pelo ritmo da restrição (tambor). O tambor define a liberação de novos lotes ou unidades de trabalho. E para proteger o sistema de flutuações estatísticas, pulmões (estoques) são adicionados em pontos chave do sistema. O objetivo final é maximizar o ganho e minimizar o tempo de atravessamento (BLACKSTONE JR, 2010).

O objetivo TOC quando aplicada às cadeias de suprimento consiste em responder à três perguntas (o que, onde e quando) se deve ter disponibilidade dos itens em todos os pontos de consumo (os usuários finais). Este objetivo é limitado pela disponibilidade de fluxo de caixa e de espaço, o que significa que é impossível manter elevados níveis de todos os itens em todos os locais, mesmo quando obsolescência não é um problema. Para responder à essas três perguntas (o que, onde, quando), a solução da TOC para a distribuição é baseada na constante renovação dos produtos consumidos de pulmões (estoques) estrategicamente localizados (SCHRAGENHEIM, 2010). A solução é composta de seis passos:

- Estoque agregado ao mais alto nível na cadeia de abastecimento, no depósito junto à fábrica;
- Determinar os tamanhos dos pulmões (estoques) para todos os locais da cadeia de suprimentos e todos os produtos com base na demanda e tempo de atravessamento;
- Aumentar a frequência de reabastecimento;
- Monitorar os pulmões (estoques) e o tamanho dos mesmos, revisando-os se necessário;
- Usar o Gerenciamento Dinâmico do Pulmão (GDP);
- Determinar as prioridades de fabricação de acordo com a urgência nos pulmões (estoques) do depósito localizado junto à fábrica.

No entanto, aliado à agregação do estoque no nível mais alto da cadeia deve ser acoplado um sistema de reposição puxado, a partir do ponto de consumo. Esse método busca reduzir o estoque ao menor nível possível, mantendo o nível de serviço. Com isso, os ruídos e

variações da demanda são reduzidos, já que poderão atender demandas em diferentes locais. Já a definição do pulmão deve ser feita considerando dois pontos principais: a taxa de demanda e a capacidade de resposta da cadeia de suprimentos. A taxa de demanda é a quantidade de produtos demandada num intervalo de tempo. Já a capacidade de resposta é a velocidade com que os itens conseguem ser repostos. A velocidade é diretamente dependente do tempo de atravessamento. O tempo de atravessamento pode ser decomposto em três (SCHRAGENHEIM, 2010):

- Tempo de atravessamento de pedido: tempo transcorrido desde a colocação do pedido até a chegada dos produtos em loja;
- Tempo de atravessamento de produção: tempo utilizado para a produção de um item;
- Tempo de atravessamento de transporte: tempo utilizado para transportar do estoque central até a loja.

O aumento da frequência de reabastecimento trás um aumento de custos de transporte atrelado, já que a escala é importante nesse quesito. No entanto, o ganho com o giro do estoque e com a disponibilidade de produtos supera essa pequena perda, se comparada com os ganhos. O uso do gerenciamento dinâmico do pulmão se refere a adaptar o estoque às variações de consumo. E definir a prioridade de acordo com o consumo do pulmão do estoque localizado junto à fábrica diminui o risco da falta de produtos (SCHRAGENHEIM, 2010).

2.2 MODA RÁPIDA (*FAST FASHION*)

As redes varejistas de *Fast Fashion* (moda rápida) são empresas aptas a responderem rapidamente às tendências do mercado. Lançam novos produtos frequentemente, com ciclo de vida curto (CARO; MARTINEZ-DE-ALBENIZ, 2009). A Moda rápida é uma estratégia de negócios que visa reduzir os processos envolvidos no processo de compra bem como os tempos de atravessamento. Com isso, objetiva levar novos produtos de moda às lojas, a fim de satisfazer a demanda dos consumidores no seu auge (BARNES; LEA-GREENWOOD, 2006).

Moda rápida trata da capacidade de reagir às tendências e melhorar os tempos de resposta (HAYES; JONES, 2006), portanto, a estratégia está relacionada com o conceito de gestão da cadeia de suprimentos e *Quick Response* (BARNES; LEA-GREENWOOD, 2006).

Geralmente duas capacidades básicas são identificadas em varejistas de moda rápida: reduzidos tempos de atravessamento de produção e distribuição; e desenvolvimento de produtos com design avançado, ou seja, acompanhando as tendências da moda (CACHON; SWINNEY, 2011). Em função disso, um elevado número de artigos (produtos) é verificado em comparação com os concorrentes tradicionais.

O mercado de moda se encontra em nível altamente competitivo e a necessidade constante de atualizar gamas de produtos significa que existe um movimento para que os varejistas aumentem o número de estações, ou seja, a frequência com que as mercadorias são alteradas na loja. Em casos extremos, exemplificado pelo caso da varejista de moda Zara, pode haver até vinte estações em um ano (CHRISTOPHER et al., 2004).

A espanhola Inditex é a proprietária da marca Zara e de outras cinco marcas. Seu modelo de negócio levou a Zara a uma condição distinta: a maioria dos seus produtos mais sensíveis a variações de moda são produzidas em fábricas próprias. Os *designers* da Zara se adaptam continuamente às preferências dos clientes colocando pedidos em fornecedores internos e externos. São 11.000 itens, contra uma média de 2.000 a 4.000 da concorrência. A produção ocorre em pequenos lotes, com a distinta integração vertical para os produtos mais sensíveis à moda. Tanto os produtos manufaturados internamente como externamente são direcionados para um centro de distribuição central. E desse centro de distribuição, duas vezes por semana reposições são destinadas a todas as lojas, diminuindo a necessidade de espaço para estocagem. Essa integração vertical auxilia na redução do efeito chicote, que é a ampliação das flutuações da demanda ao longo da cadeia de suprimentos. O resultado desse sistema é que o tempo de atravessamento do *design* até o produto pronto na loja é de cinco semanas. Já modificações de *design* são feitas em duas semanas. A indústria tradicional, no entanto, necessita de ciclos de seis meses para desenvolver novos produtos e de três meses para a produção. Isso permite à Zara realizar aproximadamente 35% do desenvolvimento e compra de matéria prima após o início da estação de vendas, bem como 40%-50% da compra de fornecedores externos e 85% da produção interna (GHEMAWAT; NUENO, 2003).

A metade dos tecidos comprados pela Zara são comprados sem cor, para serem tingidos segundo a demanda. A Comditel, empresa de tingimento de tecidos propriedade da Inditex, é responsável por esse processo, tanto para a Zara quanto para as outras marcas do grupo. O processo de tingimento tem um tempo de atravessamento de aproximadamente uma semana. Avançando na cadeia de suprimentos, aproximadamente 40% dos produtos vendidos são produzidos internamente. Os produtos mais suscetíveis às tendências da moda são os que oferecem mais risco, e são produzidos em pequenos lotes internamente. Se venderem bem,

ordens de reposição são feitas. Os produtos mais básicos, mais sensíveis à preço que à moda (tempo em que é lançado, como uma camiseta branca), são normalmente comprados dos fornecedores asiáticos. Os fornecedores europeus são aproximadamente 15%-20% mais caros que os asiáticos (GHEMAWAT; NUENO, 2003).

As fábricas internas da Zara são altamente automatizadas, especialmente as etapas de corte. A costura das peças é realizada em sua maioria em seus mais de 450 fornecedores desse serviço. A inspeção final, a embalagem e a etiquetagem são realizadas internamente antes do envio ao centro de distribuição principal. Desde os anos de 1990, altos investimentos foram realizados para implantar um sistema *Just-in-time*, em parceria com Toyota. Esse foi um dos primeiros experimentos desse tipo na Europa. Com isso, os funcionários tiveram que aprender a operar mais de um equipamento e a trabalhar em células de manufatura. A Zara prioriza por integração vertical o atendimento puxado à demanda. Com isso busca se tornar uma seguidora das tendências de moda muito rápida ao invés de colocar grandes pedidos antes do início da coleção que proporcionem eficiência para a produção (GHEMAWAT; NUENO, 2003).

2.3 PREVISÃO DE DEMANDA

Previsão de demanda é uma estimativa provável e plausível de um valor futuro de uma grandeza de interesse. O pressuposto básico da maioria dos métodos de previsão de demanda é que os padrões ou comportamentos passados valerão no futuro. Assim, padrões do passado são modelados e projetados para o futuro (FRANK et al., 2003). A previsão de demanda somente é necessária se houver incerteza a respeito do futuro. Tomadas de decisão envolvendo resultados empresariais normalmente utilizam métodos formais de previsão de demanda (ARMSTRONG, 2001).

Os objetivos básicos da previsão de demanda são (MORETTIN; TOLOI, 1987):

- Modelagem do fenômeno sob consideração;
- Obtenção de conclusões em termos estatísticos; e
- Avaliação do modelo em termos de previsão.

Para Armstrong (2001), as principais etapas de uma previsão de demanda são: formular o problema, obter dados, selecionar o método de previsão, implementar o método, avaliar o método, e por fim utilizar a previsão de demanda. A sequência sugerida pode ser visualizada na Figura 2.

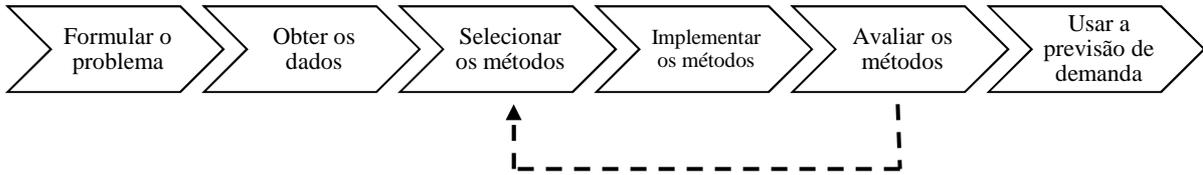


Figura 2 - Etapas da previsão de demanda

Fonte: adaptado de Armstrong (2001)

2.3.1 Métodos de Previsão

Os métodos de previsão de demanda podem ser classificados em quantitativos e qualitativos (HANKE; WICHERN, 2001; MAKRIDAKIS et al., 1998). Técnicas puramente qualitativas não requerem manipulação de dados: somente julgamentos são utilizados para criar a previsão. Técnicas puramente quantitativas não necessitam de julgamento: são procedimentos padronizados que produzem resultados objetivos (HANKE; WICHERN, 2001). A Figura 3 apresenta como os métodos de previsão de demanda são agrupados.

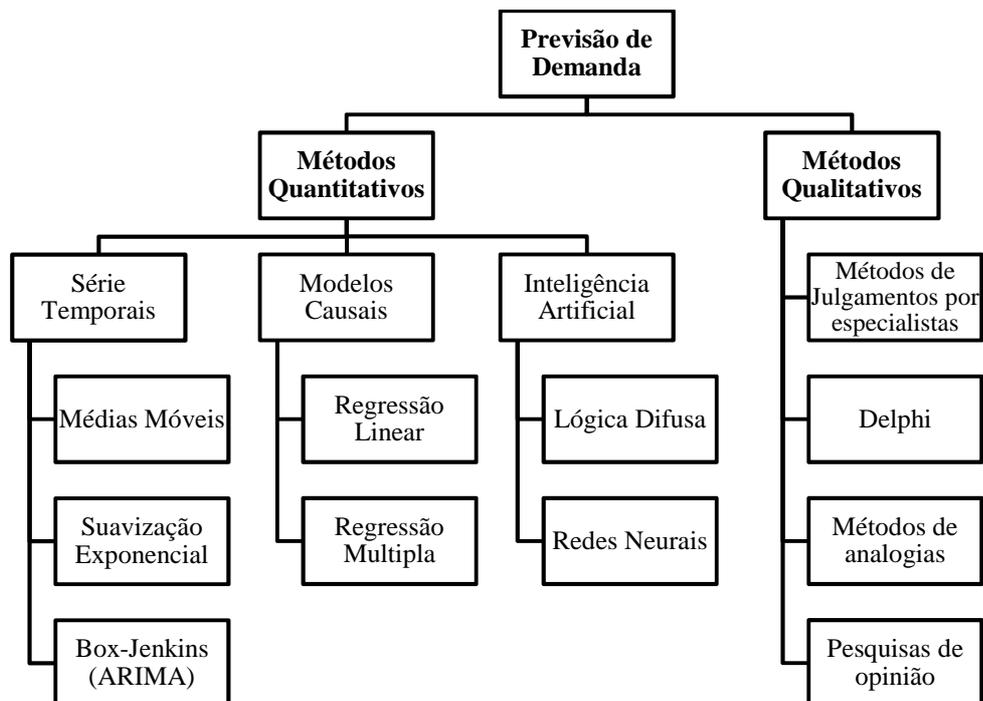


Figura 3 – Métodos de Previsão de Demanda

Fonte: adaptado de Armstrong e Green (2005) e Frank et al. (2003)

2.3.2 Métodos Qualitativos

Os métodos qualitativos são considerados métodos de predição, baseados no julgamento, intuição ou experiência dos envolvidos. São usados para criar cenários futuros, quando apenas poucos dados relevantes para o objetivo da previsão estão disponíveis, como padrões e relações causais. Os métodos qualitativos são úteis quando existem poucos dados para apoiar os métodos quantitativos. Normalmente a previsão de demanda para novos produtos e novas tecnologias apresenta poucos dados históricos, ou nenhum padrão ou relação causal clara. Geralmente métodos qualitativos são usados nessas condições (FRANK et al., 2003). Os métodos qualitativos mais utilizados são apresentados no Quadro 1.

Método Qualitativo	Descrição
Métodos de julgamentos por especialistas	São métodos que utilizam a opinião e a experiência de especialistas para comporem a predição de demanda. Uma das técnicas é o julgamento por decomposição. A ideia básica é dividir o problema em partes, mais fáceis de prever do que o todo. O especialista então realiza a previsão individualmente e as partes são combinadas para se obter a previsão agregada. A autoavancagem por julgamento permite que dados preditos por especialistas sejam utilizados em modelos matemáticos, convertendo julgamentos subjetivos em procedimentos estruturados. Primeiramente são identificadas as informações que são utilizadas pelos especialistas para preverem demandas. Então os especialistas realizam previsões para diversos casos, reais ou hipotéticos. Os dados resultantes são convertidos para um modelo estimando uma regressão em função do conjunto de previsões coletadas.
Delphi	A técnica Delphi foi desenvolvida na década de 1950 para utilizar conjuntamente o conhecimento de diversos especialistas, evitando as desvantagens de reuniões de grupos tradicionais. Normalmente se utiliza entre cinco e vinte especialistas. Anonimamente, os especialistas respondem formulários com suas previsões e o porquê das mesmas. O processo é repetido até que haja pouca alteração nas previsões entre as rodadas - dois ou três normalmente são suficientes. A previsão será a mediana ou a moda das previsões finais dos peritos.
Métodos de analogias	Comportamentos passados podem ajudar um varejista a prever o resultado de uma nova situação (analogias). Por exemplo, a introdução de novos produtos nos mercados de um determinado país podem fornecer analogias para os resultados da de uma introdução desses novos produtos em outros países.
Pesquisas de Intenção e Opinião	Pesquisas de Intenção são realizadas para verificação das intenções de compra ou padrões de comportamento sob determinadas condições. Somente devem ser consideradas <i>surveys</i> com significância estatística para generalizações. Muitas vezes são usados grupos focados para esse fim, o que não se trata de uma amostra significativa da população. Também fazem parte desse grupo as análises conjuntas, quando a pesquisa é realizada com a intenção de perceber os atributos que

levariam a uma opção de compra ou um padrão de comportamento.

Quadro 1 – Métodos Qualitativos

Fonte: adaptado de Armstrong e Green (2005) e Frank et al. (2003)

2.3.3 Métodos Quantitativos

Métodos quantitativos de previsão utilizam padrão histórico de dados para extrapolar o comportamento futuro. São identificados dois grupos de ferramentas quantitativas: séries temporais e modelos causais. Além destes, existem os que utilizam inteligência artificial para realizar previsões. As análises de séries temporais são também consideradas análises univariadas, porque geralmente usam tempo como a única variável, sem utilizar nenhuma outra variável (FRANK et al., 2003). Os modelos utilizando análises de séries temporais, por excluírem relações causais, não devem ser seguidas sem considerações de outros fatores do negócio (MAKRIDAKIS et al., 1998). Modelos causais são modelos usados para estabelecer relações causa-efeito em um sistema, como por exemplo vendas em função de preço, publicidade e competição (FRANK et al., 2003). Descrevem a demanda como função dessas variáveis independentes.

2.3.4 Séries Temporais

Uma série temporal é um conjunto de observações ordenadas no tempo, ou seja, uma sequência de valores que seguem uma ordem crescente ou decrescente não aleatória. A análise das séries temporais é baseada na suposição de que valores sucessivos dos dados representam formas de medidas consecutivas tomadas em intervalos de tempos iguais, denominadas séries discretas (MORETTIN; TOLOI, 1987). É possível decompor séries em componentes de tendência, sazonal, cíclicos e irregular. O componente de tendência representa o comportamento de longo prazo da série temporal. O componente cíclico representa movimentos regulares periódicos. O componente irregular é estocástico e de alguma forma previsível (ENDERS, 2010). Toda variação em uma série modelada como uma série temporal clássica que não pode ser explicada pelas características acima é devida ao ruído aleatório no processo gerador dos dados (MAKRIDAKIS et al., 1998). Tal ruído não é matematicamente modelável, mas pode ser tratado ou seu efeito reduzido pela aplicação de filtros, tal como o filtro de Kalman (HAMILTON, 1994).

Utilizando as metodologias desenvolvidas no estudo das séries temporais é possível decompor uma série nos componentes de tendência, sazonalidade e irregular, como na Figura

4. Como se pode ver, a tendência muda a média da série, e o componente sazonal impõe um padrão cíclico regular com picos ocorrendo a cada doze unidades de tempo. O componente irregular, ao longo de toda a série, apresenta uma tendência de se aproximar de zero, apesar de corridas tanto positivas como negativas.

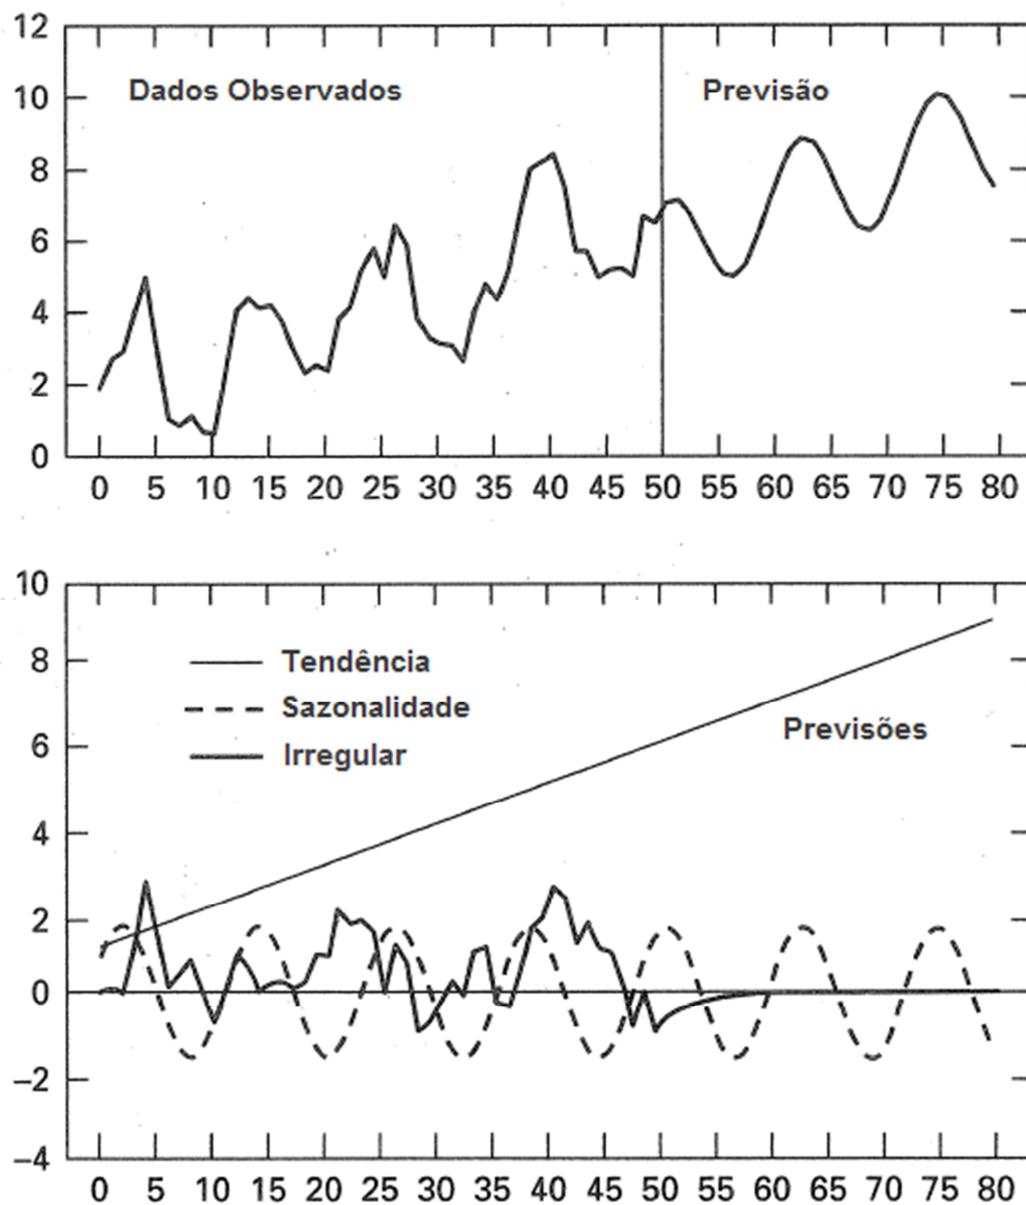


Figura 4 – Características de séries temporais

Fonte: adaptado de Enders (2010)

De maneira geral, existem cinco técnicas baseadas em análise de séries temporais: (1) métodos de suavização exponencial, (2) modelos de regressão de equação única, (3) modelos de regressão de equações simultâneas, (4) modelos autorregressivos integrados a média móvel (ARIMA), e (5) vetores de autorregressão (VAR) (GUJARATI, 2004).

Suavização exponencial utiliza o princípio de que os dados mais recentes devem receber pesos maiores e suaviza as flutuações cíclicas para prever a tendência (FRANK et al., 2003). Para usar essa técnica, deve-se primeiro limpar e desazonalizar os dados, selecionando fatores de suavização razoáveis. Então, calcula-se a média e a tendência a partir dos dados e se obtém uma previsão. Esses métodos procuram captar as informações contidas nos próprios valores da série, ou seja, buscam traduzir as influências ocorridas nas observações ao longo do tempo através delas mesmas. Se um fato externo acarreta mudanças de valores da variável em estudo, então a consequência deste fato já está embutida nos valores observados passados que resultarão em respostas futuras (MAKRIDAKIS et al., 1998).

Em sua essência, a suavização exponencial é um método de ajustar uma curva apropriada para os dados históricos de uma determinada série temporal. Há uma variedade desses métodos, como suavização exponencial simples, método linear de Holt, e método de Holt-Winters e suas variações. Apesar de ainda ser utilizado em diversas áreas de negócio e previsão econômica, estes métodos estão sendo considerados superados pelos demais métodos citados anteriormente (GUJARATI, 2004).

Como um exemplo de um modelo de regressão de equação única, pode-se considerar uma função de demanda por automóveis. Com base na teoria econômica, postula-se que a demanda por automóveis é uma função dos preços de automóveis, despesas de publicidade, salário do consumidor, a taxa de interesse (como uma medida do custo dos empréstimos), e de outras variáveis relevantes (por exemplo, família, tamanho, distância de deslocamento para o trabalho). A partir de dados de séries temporais, estima-se um modelo adequado da demanda de automóveis (um linear, log-linear ou não linear), que pode ser usado para prever a demanda por automóveis no futuro. No entanto, os erros de previsão aumentam rapidamente se a previsão avançar muito longe no futuro. Já os modelos de regressão de equações simultâneas são necessários quando “x” depende de “y” e “y” depende de “x”, ou seja, não existe uma variável independente, ambas são causa e efeito (GUJARATI, 2004)

Modelos ARIMA (Box-Jenkins) modelam a série usando coeficientes de tendência, sazonalidade e suavização baseados em médias móveis, autorregressão, e equações diferenciais (FRANK et al., 2003). Os modelos de Box-Jenkins, também conhecidos como Modelos Autorregressivos Integrados a Média Móvel, ou simplesmente ARIMA (*Autoregressive Integrated Moving Average*), foram propostos por George Box e Gwilym Jenkins no início dos anos 1970 (BOX et al., 1994). Os principais recursos utilizados para a identificação e diagnóstico das séries onde se possa utilizar o Método ARIMA são as funções de autocorrelação (FAC) e autocorrelação parcial (FACP). Se determinada série apresenta

uma FAC e uma FACP com características similares ao de um processo estocástico, então é possível modelar a série por esse método (MORETTIN; TOLOI, 1987). A ênfase desse método é analisar as propriedades estocásticas da série temporal, deixando os dados falarem por eles mesmos. Por vezes, esses modelos são chamados de ateoréticos, já que não são derivados de nenhuma teoria econômica (GUJARATI, 2004).

Metodologia VAR superficialmente se assemelha a de equações simultâneas de modelagem em que se consideram diversas variáveis endógenas juntas. Mas cada variável endógena é explicada por sua defasagem, ou seja, os valores e os valores defasados de todas as outras variáveis endógenas do modelo. Normalmente, não existem variáveis exógenas do modelo (GUJARATI, 2004).

2.3.5 Modelos Causais

Modelos causais são baseadas em conhecimento prévio e teoria. Regressão de séries temporais e de regressão transversal são comumente usados para estimar os parâmetros do modelo ou coeficientes. Estes modelos permitem examinar os efeitos da atividade de marketing, como uma mudança no preço, bem como os aspectos-chave do mercado, proporcionando assim informações para o planejamento de uma contingência (ARMSTRONG; GREEN, 2005).

Para o desenvolvimento de modelos causais, é preciso selecionar as variáveis causais usando teoria e conhecimento prévio. A chave é identificar variáveis importantes, a direção de seus efeitos, bem como quaisquer restrições. Deve-se apontar para um modelo relativamente simples e usar todos os dados disponíveis para estimá-lo (ARMSTRONG, 2001). Os procedimentos estatísticos sofisticados nem sempre levam a previsões mais precisas. Estimativas simples são muitas vezes suficientes para fornecer previsões precisas ao usar dados transversais (DANA; DAWES, 2004).

Modelos causais são mais úteis quando: (1) relações causais fortes são esperadas, (2) a direção da relação é conhecida, (3) as relações causais são conhecidas ou podem ser estimadas (4), é esperado que ocorram grandes mudanças nas variáveis causais ao longo do horizonte de previsão, e (5) alterações nas variáveis causais podem ser previstas com exatidão ou controladas, especialmente quanto à sua direção (ARMSTRONG; GREEN, 2005).

A regressão linear simples analisa a relação entre duas variáveis. Os dados apropriados para este método consistem em observações, cada uma delas com duas medidas diferentes. Tem-se uma variável independente (variável x) e uma dependente (variável y), sendo que a

primeira causa mudanças na segunda. A regressão linear múltipla analisa a relação entre mais de duas variáveis dependentes (MONTGOMERY; RUNGER, 2003).

O método de Levenberg-Marquardt é uma técnica padrão usada para resolver problemas não lineares de mínimos quadrados. Problemas lineares de mínimos quadrados buscam ajustar uma função parametrizada para um conjunto de dados minimizando o somatório do quadrado dos erros entre os dados e a função. Problemas não lineares de mínimos quadrados surgem quando a função não é linear dentro dos parâmetros. Os métodos não lineares por mínimos quadrados utilizam uma melhoria iterativa para os valores dos parâmetros, buscando reduzir a soma dos quadrados dos erros entre a função e os pontos de dados medidos. O método de ajuste de curva de Levenberg-Marquardt é efetivamente uma combinação de dois métodos de minimização: o método do gradiente descendente e o método de Gauss-Newton. No método do gradiente descendente, a soma dos quadrados dos erros é reduzido, atualizando os parâmetros no sentido da maior redução dos mínimos quadrados objetivos. No método de Gauss-Newton, a soma dos quadrados dos erros é reduzida assumindo que a função de mínimos quadrados é localmente quadrática, e buscando encontrar o mínimo da potência quadrática. O método de Levenberg-Marquardt age mais como um método de gradiente descendente quando os parâmetros estão longe de seu valor ideal, e atua mais como o método de Gauss-Newton quando os parâmetros estão perto de seu valor ideal (GAVIN, 2013).

2.3.5.1 Modelo Logístico

Em 1838, Pierre François Verhulst publicou a equação logística (YANG; WILLIAMS, 2009). Verhulst propôs que a taxa de crescimento por habitante deve diminuir linearmente com a população, uma abordagem que mais tarde ficou conhecido como o modelo logístico. Este modelo tem sido amplamente usado para tratar uma variedade de processos de crescimento evolutivos, dado que incorpora duas características fundamentais da evolução das populações biológicas: (i) taxas exponenciais iniciais de crescimento, e (ii) os efeitos dependentes da população, como a concorrência com recursos limitados, levando à saturação da população (MIRANDA; LIMA, 2010). O pressuposto fundamental da curva logística é que existe um limite para o crescimento da curva ou limite assintótico (BODGER; TAY, 1987). Essa classe de modelos também é largamente utilizada para prever a difusão de novas tecnologias. Tem-se observado que a adoção de novas tecnologias pode ser modelada como uma curva logística ou em forma de “S”. Isso porque a tecnologia não é adotada de uma só

vez. Alguns *early adopters* (pessoas que adotam novas tecnologias muito cedo) passam a utilizar a tecnologia. Se a adoção obtiver sucesso com esse público, uma reação em cadeia faz com que clientes potenciais os imitem, adotando a tecnologia. A imitação cresce na forma de um “S”, até atingir a saturação (QUADDUS, 1986).

O modelo para a curva logística simples é controlado por três coeficientes a , b e c , e é expressa pela equação 1 (TRAPPEY; WU, 2008):

$$y_t = \frac{a}{1 + be^{-ct}} \quad (1)$$

onde y_t é o valor de interesse, a é o valor máximo de y_t , b descreve o local da curva, e c controla a forma da curva. A característica mais importante do modelo logístico simples é que ele é simétrico em torno do ponto de inflexão. Essa característica indica que o processo que vai acontecer após o ponto de inflexão é o espelho do processo que aconteceu antes dele (TRAPPEY; WU, 2008).

2.3.6 Métodos com utilização de Inteligência Artificial

As redes neurais artificiais (RNA) foram desenvolvidas na tentativa de simular o processo de aprendizagem cognitiva do cérebro animal. No entanto, as RNA's provaram ser eficientes na modelagem de problemas complexos e superficialmente compreendidos para os quais dados suficientes forem coletados (DHAR; STEIN, 1997). A capacidade aprendizagem de exemplos é, provavelmente, a propriedade mais importante de redes de neurais em suas aplicações e pode ser usada para treinar uma rede neural com os dados históricos de um sistema complexo (WEI et al., 1997).

O elemento básico de uma rede neural é o neurônio. Cada neurônio está ligado a alguns dos seus vizinhos com diferentes coeficientes de conectividade que representam os pontos fortes destas conexões. A aprendizagem é alcançada ajustando a sua força para que os neurônios possam ser agrupados em camadas (*layers*). A camada de entrada é composta por neurônios que recebem estímulos a partir do ambiente externo. A camada de saída é constituída por neurônios que comunicam a saída do sistema para o usuário ou para o ambiente externo. Pode haver camadas escondidas entre estas duas camadas. As camadas ocultas de um modelo de RNA agem como uma caixa preta conectando o relacionamento entre entrada e saída (CHOY et al., 2003). Quando a relação entre as variáveis de entrada e de

saída são não lineares, uma camada oculta pode ajudar na extração de níveis mais altos dos neurônios, facilitando a generalização de saídas (KOSKIVAARA, 2004).

Durante o processo de treinamento, os pesos da rede gradualmente convergem para determinados valores, de modo que a aplicação dos vetores de entrada produzam as saídas necessárias. Os métodos de aprendizagem podem ser divididos em duas categorias: a aprendizagem não supervisionada e a supervisionada. Para a aprendizagem não supervisionada, a rede precisa aprender sozinho relações, padrões, regularidades ou categorias nos dados de entrada e codificá-los nas saídas. A aprendizagem supervisionada verifica o erro entre a saída esperada e a saída calculada. Então, um procedimento de minimização é usado para ajustar os pesos entre duas camadas de ligação da camada de saída para a camada de entrada. Existem diversas variações dos procedimentos de minimização que são baseados em diferentes métodos de otimização. Exemplos desses métodos são o gradiente descendente, o gradiente conjugado, Quasi-Newton e métodos de Levenberg-Marquardt (HAYKIN, 1999; MANEVITZ et al., 2005).

Por vezes, a modelagem de sistemas com base em ferramentas matemáticas convencionais não é adequada para lidar com sistemas mal definidos e incertos. Por outro lado, um sistema de lógica difusa (*Fuzzy Logic*) empregando regras “se-então” pode modelar os aspectos qualitativos do conhecimento humano e o processo de raciocínio sem o emprego de análises quantitativas precisas (JANG, 1993).

A abordagem de análise numérica para sistemas difusos foi apresentada pela primeira vez por Takagi e Sugeno (1985). Uma vez que os sistemas utilizando lógica difusa podem expressar regras ou conhecimento como forma “se-então”, eles apresentam vantagens, pois não necessitam de análise matemática para a modelagem. No entanto, eles exigem a construção do modelo apropriado e a seleção de parâmetros. A eliminação de regras desnecessárias e a seleção de elementos de entrada eficientes podem contribuir para a melhoria de desempenho, redução de custos de cálculo e análise das regras obtidas, o que é uma das características mais importantes dos sistemas difusos (IYATOMI; HAGIWARA, 2004).

Combinações de redes neurais e sistemas de lógica difusa (ou sistemas *neuro-fuzzy*) têm sido reconhecidas como uma abordagem alternativa poderosa para desenvolver sistemas com lógica difusa (FIGUEIREDO; GOMIDE, 1999). Em sistemas de lógica difusa, as relações de entrada e saída são representadas explicitamente na forma de regras “se-então”. No entanto, em redes neurais as mesmas relações não estão explicitamente definidas, mas estão "codificadas" na rede neural por seus parâmetros. Em contraste com as técnicas

baseadas no conhecimento, nenhum conhecimento explícito é necessário em aplicações de redes neurais. Por outro lado, os sistemas *neuro-fuzzy* combinam a transparência semântica de sistemas com lógica difusa baseados em regras com a capacidade de aprendizagem de redes neurais (BABUŠKA; VERBRUGGEN, 2003). Além disso, a modelagem *neuro-fuzzy* tem sido reconhecida como uma ferramenta poderosa que pode facilitar o desenvolvimento eficaz de modelos, combinando informações de várias fontes, tais como modelos empíricos, heurística e dados. Assim, na maioria dos casos os modelos *neuro-fuzzy* podem ser melhor utilizados para explicar as soluções para os usuários do que os modelos com as camadas intermediárias completamente indefinidas, como redes neurais (BABUŠKA; VERBRUGGEN, 2003; PANCHARIYA et al., 2004).

Segundo Liu et al. (2013), ainda são encontrados mais três métodos baseados em redes neurais para previsão de demanda: (a) *Evolutionary Neural Networks – ENN* (redes neurais evolucionárias), (b) *Extreme Learning Machines – ELM* (máquinas de aprendizado extremo), e (c) *Extended Extreme Learning Machines – EELM* (máquinas de aprendizado extremo estendidas).

2.3.7 Medidas de Desempenho Preditivo

Toda demanda possui um componente aleatório. Um modelo de demanda deve captar o componente sistemático da demanda, mas não o aleatório. Esse componente aleatório se manifesta na forma do erro de previsão (CHOPRA; MEINDL, 2003). Como o futuro não é espelhado perfeitamente pelo passado, a previsão da demanda futura conterà erros em algum nível. O erro de previsão é definido como a diferença entre a demanda real e a demanda prevista (BALLOU, 2006).

Dependendo do comportamento da série temporal que se deseja analisar, vários modelos podem ser empregados na previsão de seus valores futuros. A escolha do modelo mais apropriado é feita a partir do somatório dos erros gerados por cada modelo. Uma vez que o cálculo dos erros pode resultar em valores positivos e negativos, zerando assim o seu somatório, diferentes formas de cálculo para o somatório dos erros podem ser empregadas. Estas diferentes formas de cálculo constituem-se em critérios para escolha de modelos mais apropriados a séries temporais. Os critérios mais utilizados são a média dos quadrados dos erros (MQE) ou *mean squared error* (MSE) em inglês; a média absoluta dos erros (MAE) ou *mean absolute error* em inglês e a média absoluta percentual dos erros (MAPE) ou *mean absolute percentage error* em inglês (PELLEGRINI; FOGLIATTO, 2001). Os APE's

(*absolute percentual errors* ou erro percentual absoluto) são os valores absolutos percentuais, dos quais o MAPE faz a média (MAKRIDAKIS, 1993).

As equações de (4) a (7) expressam as grandezas.

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (4)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (5)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{z_t} \times 100 \right| \quad (6)$$

$$APE = \left| \frac{A-P}{A} \right| \quad (7)$$

sendo A o valor atual observado e P o valor previsto pelo modelo; $e_t = A - P$; $z_t =$ demanda observada no período.

As métricas MSE e MAE resultam em valores com unidades iguais à variável original. Um resultado zero significa perfeita adequação do modelo. Portanto, quanto mais próxima de zero, melhor o resultado da previsão. Já o MAPE consiste na relação percentual entre os erros e a demanda observada. Por ter um resultado intuitivamente mais simples, tem seu uso aconselhado para tomadores de decisão não acostumados às medianas e médias geométricas. Da mesma forma que os anteriores, quanto mais próximo de zero, melhor será a adequação da previsão do modelo aos dados reais (MAKRIDAKIS; HIBON, 1995; MAKRIDAKIS, 1993).

A métrica MAPE, no entanto, pode não ser diretamente aplicável ao nível de produto considerando somente uma loja. Isso porque em algumas lojas, alguns produtos de giro de estoque baixo podem apresentar semanas com demanda zero. Isso impossibilita o cálculo dessa medida para todos os períodos, o que retiraria da amostra os períodos em que a demanda é extremamente baixa. Então, um MAPE modificado, indicado como MAPE*, pode ser utilizado para evitar o problema dos períodos em que a demanda é zero. Esta métrica simplesmente avalia o MAE e compara com a demanda total, permitindo então a comparação entre previsões diferentes. Com isso, é possível reduzir o viés do MAPE que existe nessa situação particular (ZOTTERI et al., 2005). A equação 8 expressa a MAPE*.

$$MAPE * = \frac{1}{n} \sum_{t=1}^n |e_t| / \frac{1}{n} \sum_{t=1}^n z_t \quad (8)$$

Não existe um melhor método de avaliação. Essa condição varia de acordo com o objetivo da previsão. Comparando-se 11 métodos de previsão, e avaliando-se os resultados utilizando 6 diferentes medidas de avaliação preditiva, verificou-se que a correlação entre as medidas apresentou resultados relativamente baixos, com mediana de 0,4. Isso significa que o desempenho da previsão depende da medida a ser adotada (ARMSTRONG, 2001). O MAPE normalmente é uma boa opção quando o objetivo é comparar previsões diferentes, já que compara relações percentuais. Por outro lado, a MSE é indicada quando pequenos erros são tolerados, mas não é desejável que se verifiquem grandes erros. Isso porque por ter um componente quadrático, quanto maior o valor do erro maior peso terá nessa métrica. Além disso, não é suscetível aos problemas do método MAPE, quando os valores de demanda são zero (MAKRIDAKIS, 1993).

Armstrong (2001) sugere que os métodos de previsão devam sempre ser avaliados contra o que eles devem prever. Assim, não é aconselhável utilizar medidas de desempenho preditivo prevendo a própria amostra que gerou o modelo como ferramenta de decisão. Também sugere utilizar mais de um método de avaliação, em função das variações verificadas entre os mesmos. Além disso, desaconselha o uso do R^2 como medida de desempenho preditivo. O modelo pode apresentar um R^2 perfeito e os valores da previsão podem ser muito diferentes da previsão, como por outro lado o valor de R^2 pode ser ruim mas a previsão pode ser aceitável caso não ocorram variações nos dados reais. Da mesma forma, o RMSE (*root mean squared error* ou raiz da média dos quadrados dos erros) também tem seu uso desaconselhado por ter um desempenho preditivo pobre em comparação com outras medidas de desempenho preditivo.

2.4 PREVISÃO DE DEMANDA NO VAREJO

O principal objetivo da previsão de demanda no varejo de moda é prever como será a tendência de moda da próxima estação e o que os clientes estarão propensos a comprar (MATTILA, 1999). Três aspectos importantes contribuem para a complexidade da mesma: curtos ciclos de vida dos produtos, o constante aumento da variedade de produtos e a globalização de compras e manufatura. Noventa e cinco por cento dos produtos mudam de estação para estação, impedindo que dados sejam utilizados para obter previsões de demanda *a priori* (antes do início das vendas) (MOSTARD et al., 2011). Para obter a máxima acuracidade nas previsões de demanda *a priori* os varejistas têm utilizado dois métodos: a

estratégia de *preview*, quando de duas a cinco semanas antes do lançamento da coleção os clientes podem comprar antecipadamente com descontos (FISHER; RAJARAM, 2000) e comitês de especialistas, para prever demandas (FISHER et al., 2000b). Por outro lado, previsões de demanda *a posteriori* utilizam dados obtidos após o início das vendas.

Para projetar um sistema adequado e eficiente de previsão de vendas é essencial conhecer o produto, os recursos de vendas e como os varejistas usarão as previsões (ARMSTRONG, 2001). Em função disso, Thomassey (2010) elabora uma lista das principais questões a serem observadas quando sistemas de previsão de demanda para a indústria da moda estejam sendo planejados. O autor sugere que sejam observados cinco elementos: (i) o horizonte de previsão; (ii) o ciclo de vida dos produtos; (iii) o nível de agregação dos itens de estoque; (iv) a sazonalidade; e (v) variáveis explanatórias.

Normalmente os horizontes de previsão de demanda utilizados na indústria da moda são dois, um de longo prazo (um ano) que busca orientar decisões de compra e produção, e o segundo de curto prazo (poucas semanas), para ajustar ordens de compra e entregas de centros de distribuição para lojas. Para análise por parte do sistema de previsão de demanda, o ciclo de vida dos produtos é considerado desde o seu lançamento até o fim de seu período de venda. São observados três tipos de comportamentos: itens básicos, que vendem o ano inteiro; itens de moda, que vendem normalmente por um curto período de tempo e os produtos mais vendidos, que vendem o ano todo com pequenas modificações (THOMASSEY, 2010).

Com relação ao nível de agregação dos produtos, cada produto pode ter muitas variações em termos de tamanhos e cores. A questão principal é definir o critério correto para o nível de agregação de produtos. A abordagem mais comum é utilizar a segmentação por grupos de produtos. Quanto maior for o nível de desagregação dos produtos, menor a probabilidade de acerto da previsão. A sazonalidade deve ser considerada, no sentido de que os consumos podem ser afetados diretamente pela estação em vigor (inverno ou verão) (THOMASSEY, 2010).

O mercado da moda também é influenciado por diversos fatores. Esses fatores podem ser chamados de variáveis explanatórias, ou seja, questões que influenciam diretamente o comportamento das vendas. No entanto, é difícil identificar e principalmente à quantificar seu impacto. As principais variáveis são questões relacionadas às condições climáticas (chuva, temperatura); competição; feriados e datas especiais; promoções e ações publicitárias; a diversificação do sortimento de produtos; e o comportamento macroeconômico da região (THOMASSEY, 2010).

Quanto ao nível de agregação, além do critério para definição do nível ideal, existem

dois processos tradicionais para realizar a previsão de demanda: “de baixo para cima”, quando as previsões de cada item individualmente são consideradas e a soma das previsões resulta na previsão de demanda final; ou o modelo “de cima para baixo”, quando a previsão por grupo de produtos é utilizada e são utilizados dados históricos ou outros métodos para desagregar a previsão ao nível de produto, cor e tamanho (ZOTTERI et. al., 2005). Os autores também sugerem a utilização de aglomerações por padrões de comportamento das vendas, no sentido de aglomerar lojas iguais e separar as diferentes, criando previsões de demanda específicas para cada aglomerado. Mostard et al. (2011) também sugerem que produtos sejam aglomerados não por grupo de produto, mas por padrão de comportamento de venda, utilizando esse critério com o critério de aglomeração para a previsão agregada. Bell et al. (2005) propõe que a agregação seja feita por atributos comuns entre os produtos.

O trabalho de Caro e Gallien (2010) foi realizado em colaboração com a Zara e aborda o problema particular da distribuição, ao longo do tempo, de uma quantidade limitada de estoque de mercadorias entre todas as lojas da rede de varejo. Embora o problema em linhas gerais não seja específico para o varejo de moda rápida, existem várias características que são específicas para esse tipo de varejo específico (os ciclos de vida curtos, políticas exclusivas de exibição dos produtos na loja). De acordo com o processo original, cada gerente de loja recebia um comunicado semanal contendo os produtos disponíveis no estoque central para solicitar um envio para sua loja. Note-se que esse comunicado continha somente uma quantidade sugerida por referência a ser mantida no estoque da loja. Depois de considerar o inventário restante em suas respectivas lojas, gerentes de loja, então, deveriam transmitir de volta quantidades a serem expedidas (zero também era possível) para cada tamanho de cada um desses artigos. Após, uma equipe de funcionários do estoque central conciliava todos os pedidos, de todas as lojas, ajustando as quantidades de acordo com a disponibilidade de itens em estoque. O novo processo consistiu em utilizar as solicitações de envio dos gerentes de loja, juntamente com as vendas históricas do passado para construir previsões de demanda por loja. Em seguida, essas previsões, o inventário de cada referência restante tanto no armazém como em cada loja, juntamente com as decisões de sortimento de produtos planejadas seriam utilizadas como entradas para um modelo de otimização tendo quantidades de embarque como as suas variáveis de decisão.

Embora a previsão de demanda utilizada no novo processo seja uma entrada crítica, foi observado que o problema de previsão é relativamente clássico. E ele foi desenvolvido e descrito no trabalho de Correa (2007). Segundo o autor, existem três fontes de dados disponíveis para uso na previsão: os dados da loja, dados históricos de vendas e as

solicitações de envio de produtos feitas pelos gerentes das lojas. A primeira tentativa do trabalho buscou gerar uma previsão por subgrupo de produtos para todas as lojas conjuntamente, encontrando um percentual para cada loja para decompor a previsão. Considerando que cada loja é única quanto a seus clientes e comportamento de vendas, a previsão de vendas tinha de ser feita ao nível de loja. Apesar de ter tentado diversos modelos simples para encontrar o de melhor desempenho, utilizar somente as vendas da última semana do subgrupo de produtos multiplicado um fator de sazonalidade demonstrou ser a melhor alternativa. O fator de sazonalidade é usado para incluir no modelo as mudanças na demanda de acordo com o avanço da estação, de semana para semana.

Uma vez que as vendas da subfamília para a próxima semana são estimados, a previsão agregada deve ser desagregada em vendas para um indivíduo modelo, qualidade, cor e tamanho. Mais uma vez, vários métodos diferentes foram explorados, mas as principais opções estavam em utilizar o percentual de um modelo, qualidade e cor na solicitação feita pelo gerente ou as vendas do subgrupo e multiplicá-lo pela previsão do subgrupo. Assim, poder-se-ia desagregá-la na previsão para os vários modelos, artigos e cores diferentes (CORREA, 2007). O modelo adotado foi o da Equação 9:

$$Y_{ijklt} = \alpha \times \left[\frac{E_{ijklt} + X_{ijklt}}{\gamma} \right] + \beta \times \left[VSG_{t-1} \times \frac{VA_t}{VA_{t-1}} \times \frac{\sum_l X_{ijkl}}{\sum_{ijkl} X_{ijkl}} \times \frac{\sum_{t=0}^{t-1} \sum_{ijk} Y_{ijkl}}{\sum_{t=0}^{t-1} \sum_{ijkl} Y_{ijkl}} \right] \quad (9)$$

onde:

t = tempo (em semanas)

Y_{ijklt} = Venda de um produto na estação atual na semana t

onde: i = modelo; j = artigo; k = cor; l = tamanho

X_{ijkl} = Quantidade de um produto na ordem (para um determinado subgrupo)

E_{ijklt} = Estoque da loja para o produto no tempo t

VSG_{t-1} = Vendas do subgrupo na última semana

VA_t = Vendas do subgrupo para a semana atual no último ano

α , β e γ = parâmetros para calibrar a previsão aos dados históricos

Foi usado o solver do *software* Microsoft Excel para otimizar os parâmetros e reduzir o erro entre as vendas atuais e estimadas. No entanto, os testes revelaram que o modelo utilizado sozinho não apresentou bom desempenho, abaixo do desempenho da utilização das solicitações dos gerentes somente. Mas por vezes, os erros dos gerentes eram demasiadamente

grandes. Assim, para que a previsão não fosse viesada, três fontes de informação precisaram ser utilizadas: os dados da loja (estoque e vendas da última semana) combinados com o pedido do gerente formam uma parte da previsão; a segunda parte é a estrutura sugerida anteriormente na Equação 9. É vantajoso utilizar todas as diferentes fontes de dados na previsão. Isso porque essa prática dá não só o benefício de um cálculo objetivo previsto pelos dados históricos, mas também incorpora o conhecimento dos gerentes de loja no momento em que fazem a solicitação de envio de materiais. Uma vez que os gerentes estão mais próximos aos clientes, eles têm uma percepção que não pode ser prevista por um modelo (CORREA, 2007). Assim, a versão final agregou essas três informações no modelo, descrito nas Equações 10 e 11:

$$[Y_{ijklt}]_{SF} = VSG_{t-1} \times \frac{VA_t}{VA_{t-1}} \times \frac{\sum_l X_{ijkl}}{\sum_{ijkl} X_{ijkl}} \times \frac{\sum_{t=0}^{t-1} \sum_{ijk} Y_{ijkl}}{\sum_{t=0}^{t-1} \sum_{ijkl} Y_{ijkl}} \quad (10)$$

Essa estimativa foi combinada com os dados da loja e com a solicitação dos gerentes:

$$Y_{ijklt} = \alpha \times [E_{ijklt} + X^*_{ijklt}] + \beta \times [Y_{ijklt}]_{SF} \quad (11)$$

onde:

X^*_{ijkl} = Solicitações de envio de produtos feitas pelos gerentes das lojas

Utilizando técnicas de inteligência artificial, Choi et al. (2014) propuseram um modelo de previsão de demanda para a indústria de Moda Rápida chamado de 3F. O modelo utilizou uma combinação de *Extended Extreme Learning Machine (EELM)* e do método Grey (GM). EELM é um algoritmo utilizado para acelerar o aprendizado de RNA's. Já o GM é originário da teoria dos sistemas. Um sistema que apresenta características de ter tanto informações conhecidas como desconhecidas pode ser considerado um sistema cinza (nem preto, nem branco). A GM tem sido utilizada numa variedade de aplicações, devido à sua natureza versátil. Na verdade, a GM pode ser utilizado para modelar problemas com múltiplas variáveis e uma ordem arbitrária de equações diferenciais. Ela é geralmente representada como GM (C, D), em que C define a ordem de equações diferenciais empregues no método e D é o número de variáveis. As duas premissas básicas do modelo são que, para atender a indústria de Moda Rápida, um modelo precisa ao mesmo tempo obter bons resultados com poucos dados e em tempo reduzido. Assim, o modelo utiliza numa primeira instância o GM.

Caso o tempo determinado para a previsão não seja excedido, os erros da previsão do GM são utilizados como dados de entrada e a previsão é otimizada com o EELM. O método permite assim que sejam respeitadas as premissas. A previsão realizada no trabalho foi realizada com os dados de produtos segmentados em cores, ou seja, desagregada. No entanto, considerou uma previsão de demanda agregada para toda a rede de varejo analisada, não por loja.

Outros modelos de previsão de demanda que não focados em Moda Rápida foram propostos para o varejo. Alguns trabalhos realizados desde o ano 2000 e selecionados pelo autor estão listados no Quadro 2. Nota-se que a maioria dos trabalhos trata de produtos de vestuário. Mas também se verificam calçados, filmes e jogos, telefones celulares, livros, eletrônicos, cerveja e jornais. Dos vinte trabalhos selecionados, dezesseis utilizam redes neurais como parte ou como método de modelagem. No entanto, nota-se a busca de resultados melhores com a combinação e a melhoria dos métodos tradicionais. Também se nota um maior número de ocorrência de modelos a priori. Apenas um trabalho sugere um método híbrido com previsões a priori e a posteriori. Existe equilíbrio entre os tipos de agregação verificados. No entanto, a maioria dos modelos que consideraram a previsão desagregada previam produtos que se repetiam de um ano para o outro. Por fim, houve uma maior ocorrência dos modelos com periodicidade de previsão semanal. Mas se verificam previsões de periodicidade oscilando de diária à anual.

Modelo / Método	Autor	Tipo de Produto	Método	Tipo de agregação	Periodicidade
Programação linear	Correa (2007)	Vestuário	A posteriori	Desagregada	Semanal
Regressão não linear	Chung et al. (2012)	Filmes e jogos	A posteriori	Desagregada	Semanal
Árvore de decisão e Aglomerados	Thomassey (2007)	Vestuário	A priori	Agregada por atributo	Semanal
Método NM	Tanaka (2010)	Livros e eletrônicos	A posteriori	Desagregada	Semestral
Redes Neurais, lógica difusa e aprendizado Bayesiano	Ragg et al. (2002)	Jornais impressos	A priori	Desagregada	Diário
Redes Neurais	Frank et al. (2003)	Vestuário	A priori	Agregada por atributo	Mensal
	Das e Chaudhury (2006)	Calçados	A priori	Agregada	Semanal
	Au et al. (2008)	Vestuário	A priori	Desagregada	Semanal
Redes Neurais e modelo Holt-Winters	Gao et al. (2009)	Indefinido	A priori	Indefinido	Semanal
Redes Neurais e ART	Ni e Fan (2011)	Telefones Celulares	A priori e A posteriori	Desagregada	Diária
MID (modelo baseado em Redes Neurais)	Guo et al. (2013)	Vestuário e calçados	A posteriori	Agregada por cidade	Indefinido
Algoritmo Genético e <i>Fuzzy Neural Network</i>	Yin et al. (2008)	Cerveja	A priori	Desagregada	Semanal
ELM (<i>Extreme Learning Machine</i>)	Sun et al. (2008)	Vestuário	A priori	Desagregada	Diário
Modelo HI (adaptação de ELM)	Wong e Guo (2010)	Indefinido	A priori	Desagregada	Mensal, Bimestral e Anual

AD-ELM (<i>Extreme Learning Machine</i> ajustado)	Xia et al. (2012)	Não definido	A priori	Agregada por tipo de produto	Mensal
ANFIS (combinação de Redes Neurais e Lógica Difusa)	Aksoy et al. (2012)	Vestuário	A priori	Agregada por grupo de produto	Mensal
Algoritmo 3F	Choi et al. (2014)	Vestuário	A priori	Agregada por atributo	Indefinido
GELM (<i>Gray Extreme Learning Machine</i>)	Chen e Ou (2011)	Indefinido	A priori	Indefinido	Diária
Método Grey e Redes Neurais	Choi et al. (2012)	Vestuário	A priori	Agregada por atributo	Anual
Método Gray adaptado	Xia e Wong (2014)	Vestuário	A priori	Agregada por tipo de produto	Mensal

Quadro 2 – Resumo dos principais modelos de previsão de demanda propostos para o varejo desde o ano 2000.

Fonte: o autor (2014)

3 MÉTODO

3.1 MÉTODO DE PESQUISA

Método de pesquisa é a escolha de procedimentos sistemáticos que visam descrever e explicar fenômenos no ambiente estudado (RICHARDSON, 1999). É utilizado como uma ferramenta para auxiliar na construção de um conhecimento científico (TRIVIÑOS, 2001). Uma das particularidades do método científico é a tentativa de resolver problemas por meio de hipóteses que possam ser testadas se utilizando observações e experiências (GEWANDSZNAJDER, 1989). A definição de um método de pesquisa adequado para o assunto a ser pesquisado é importante para a construção de qualquer trabalho científico (TRIVIÑOS, 2001). O método científico é um procedimento que visa proporcionar respostas aos problemas propostos (GIL, 2002).

Uma das formas de se examinar um trabalho científico é pela natureza da pesquisa (básica ou aplicada). Pesquisas básicas envolvem objetivos universais, enquanto pesquisas aplicadas procuram produzir conhecimentos para aplicação prática (SILVA; MENEZES, 2001). O presente trabalho pode ser classificado como pesquisa aplicada, por buscar produzir conhecimentos de aplicação prática dirigidos à solução de problemas específicos.

Em termos dos objetivos da pesquisa, elas podem ser classificadas em: i) exploratórias; ii) descritivas; e iii) explanatórias (GIL, 2007; SILVA; MENEZES, 2001; YIN, 2005). A pesquisa realizada pode ser classificada como explanatória, pois procura identificar os fatores que causam um determinado fenômeno, aprofundando o conhecimento da realidade (GIL, 2007; YIN, 2005).

Em relação ao tipo de abordagem, é possível distinguir estudos quantitativos e qualitativos, ou ainda mistos que podem conter a composição dessas duas abordagens (SILVA; MENEZES, 2001). A pesquisa quantitativa requer o uso de recursos e técnicas estatísticas, procurando traduzir em números os conhecimentos gerados pelo pesquisador, e foi a técnica adotada pelo presente trabalho (SILVA; MENEZES, 2001). O presente trabalho pode ter sua abordagem classificada como quantitativa.

O método de pesquisa foi a modelagem quantitativa. Modelagem ou modelamento compreende o uso de técnicas matemáticas para descrever o comportamento de um objeto de estudo (MIGUEL, 2010a; NAKANO, 2010). Se for possível descrever o comportamento de um objeto por um modelo matemático, por tratamento matemático adequado, também é possível extrair conclusões a seu respeito. A modelagem é citada como método válido em

Engenharia de Produção por Nakano (2010) e foi reconhecida anteriormente como método de pesquisa em gestão de operações por Filippini (1997). Seus detalhes e características, em conjunto com simulação, incluindo aplicações em pesquisa operacional, são abordados por Morabito e Pureza (2010).

3.2 MÉTODO DE TRABALHO

Segundo Lakatos e Marconi (1990), o método de trabalho é um conjunto de atividades sistemáticas e racionais que orientam e sustentam a geração de conhecimentos válidos, direcionando assim o caminho a ser seguido. O método de trabalho empregado na pesquisa é apresentado na Figura 5.

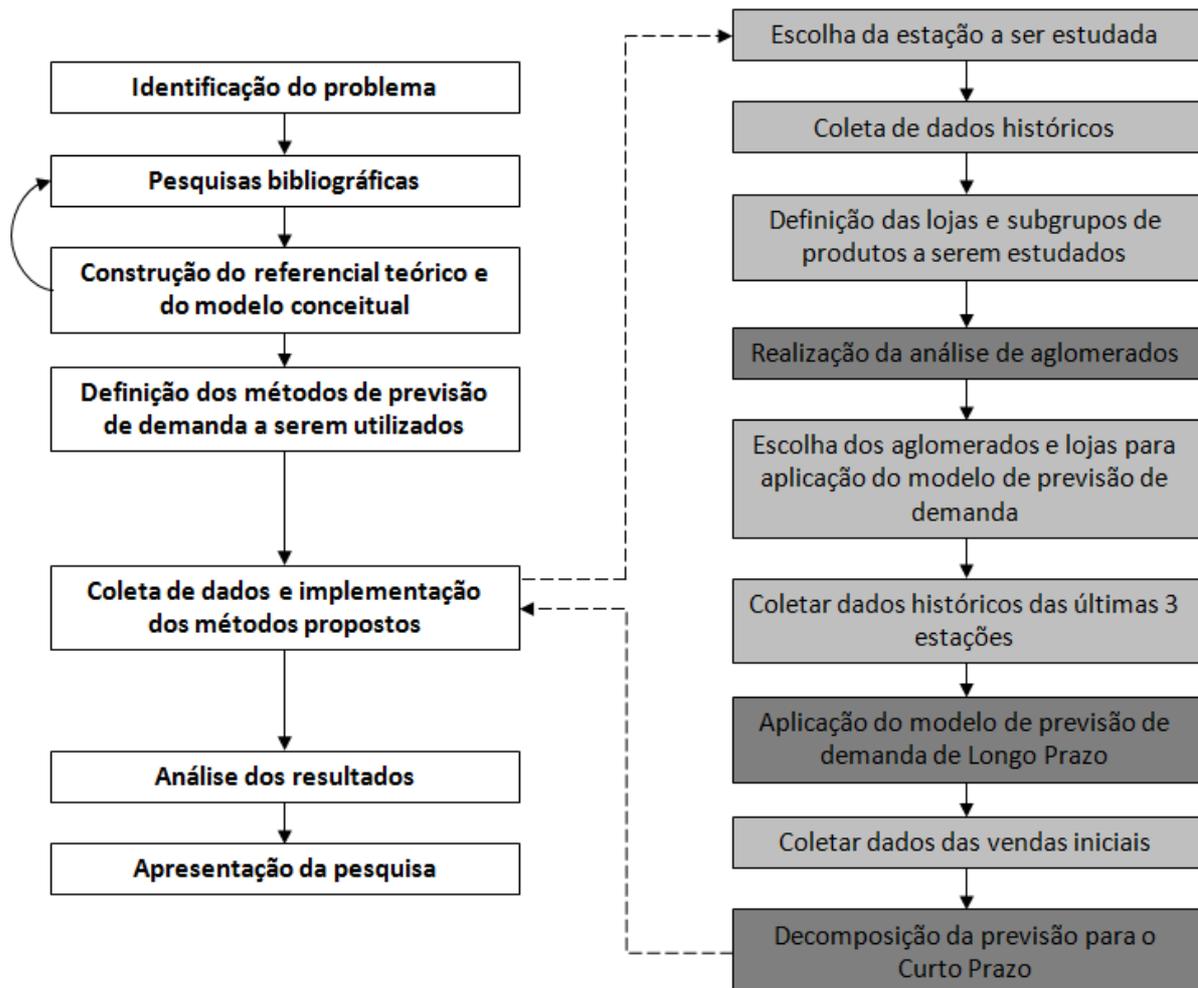


Figura 5 – Método de trabalho.

Fonte: o autor (2014)

Geralmente, ao resolver um problema, o pesquisador precisa ter claro qual o problema

e suas implicações. O que não é problemático não atrai a atenção de pessoas a buscarem uma solução (MIGUEL, 2010b). A observação do problema pelo pesquisador se deu ao identificar a dificuldade que os varejistas de calçados têm de prever a demanda por seus produtos. Não o volume total de vendas, ou a demanda agregada por grupo ou subgrupo de produtos, mas sim a demanda por item. No caso calçadista, em especial a demanda por modelo e cor de produtos. Na dúvida, as decisões acabam sendo ou conservadoras ou são previsões tão vagas que podem ser consideradas apostas. Habitualmente, ocorrem erros consideráveis para mais ou para menos. E esses erros acabam gerando distúrbios ao longo de toda a cadeia de suprimentos: pedidos urgentes, quando o erro foi uma compra menor que a demanda real, ou cancelamentos de pedidos quando a compra foi maior que a demanda real. E então, boa parte dos esforços dos gestores, tanto de clientes como de fornecedores, foca-se em resolver os problemas criados a partir desses erros. No entanto, essa postura é reativa ao problema. A discussão central da relação entre cliente e fornecedor deveria ser centrada, na opinião do pesquisador, em questões pertinentes e focadas nos objetivos principais do negócio. E a previsão de demanda e os métodos de previsão de demanda utilizados, aparentemente, são questões pertinentes.

A segunda etapa do método de trabalho foi a realização da pesquisa bibliográfica. Num primeiro momento, a pesquisa bibliográfica foi realizada considerando uma varredura horizontal, determinando os temas de interesse à pesquisa. Foram identificados os seguintes temas: Gestão da Cadeia de Suprimentos, Varejo, Moda rápida, Previsão de demanda, Gestão de estoques, Planejamento de Sortimento de Produtos ou Otimização de Sortimento de Produtos. A partir dessa pesquisa, a questão de pesquisa e os objetivos puderam ser traçados. O aprofundamento nos temas de interesse permitiu a construção da etapa subsequente, a construção do referencial teórico e do modelo conceitual. O mesmo apresenta as teorias obtidas na etapa anterior, segundo os temas pesquisados. O objetivo dessa etapa é suprir a pesquisa dos elementos necessários para a estruturação do método proposto. Durante a construção do referencial teórico, retornos à pesquisa bibliográfica se fizeram necessários, sendo que os temas foram sendo adicionados de acordo com o avanço do mesmo.

Para a definição dos métodos de previsão de demanda a serem utilizados, foram analisadas as questões sugeridas por Thomassey (2010) para construção de sistemas de previsão de demanda em ambientes de moda: (i) o horizonte de previsão; (ii) o ciclo de vida dos produtos; (iii) o nível de agregação dos itens de estoque; (iv) a sazonalidade; e (v) variáveis explanatórias. Foram buscadas informações a respeito das características do negócio para realizar a análise, aprofundando o conhecimento a respeito da empresa. O horizonte da

previsão foi definido como a estação Verão 2013/2014 (comercializada no segundo semestre de 2013 e início de 2014), ou seja, pouco mais de um semestre. No entanto, o ciclo de vida dos produtos ideal para venda gira em torno de seis semanas, semelhante ao verificado em empresas de Moda Rápida, conforme Correa (2007). Além de que uma quantidade mínima de produtos se repete com relação à estação anterior (menos de 5%), e com modificações, tanto de cores como de artigos. Essa característica inviabilizaria a previsão por produto. Mas o comportamento das vendas por grupo de produtos (previsão agregada) tende a repetir o ano anterior (ZOTTERI et al., 2005), e essa percepção já existia na empresa. Essa característica levou à adoção de dois horizontes de previsão, de longo e de curto prazo, em tempos distintos: uma primeira previsão de demanda agregada (por grupo de produto), tendo como horizonte a estação, realizada *a priori*; e uma segunda previsão realizada *a posteriori*, considerando as informações das vendas iniciais como método de desagregação da previsão por modelo e cor, com horizonte de seis semanas. Como a previsão de demanda de longo prazo foi feita com base em séries temporais, tanto sazonalidade como variáveis explanatórias já estão inclusas nos dados coletados (MAKRIDAKIS et al., 1998). Os métodos de previsão de demanda serão melhor detalhados no capítulo 4.

Foi então realizada a coleta de dados e implementação dos métodos propostos. Os dados foram coletados diretamente do sistema de ERP da empresa, e foram tabulados no software Excel. A implementação ocorreu de acordo com o que será detalhado no decorrer do presente capítulo. A análise dos resultados buscou comparar o método proposto e o método atual da empresa. Tanto a coleta como a análise dos dados serão melhor detalhadas nas seções 3.3 e 3.4 da pesquisa. Por fim, procedeu-se com a apresentação da pesquisa, onde os resultados foram organizados por meio da elaboração do presente relatório.

3.2.1 Modelo Conceitual

Fisher et al. (2000a) sugerem que quatro elementos são importantes para a evolução da pesquisa no varejo: (i) dados disponíveis e precisos, (ii) previsão de demanda, (iii) planejamento de estoques baseados no risco e (iv) velocidade da cadeia de suprimentos. Buscando identificar os fatores críticos para o sucesso associados à aquisição de produtos sazonais de moda, Mattila (1999) sugere também quatro fatores: (i) a acuracidade da previsão de demanda, (ii) o tempo de atravessamento (*lead time*) do processo, (iii) o composto de compra no mercado externo e no mercado interno e (iv) a relação entre compra inicial e reposições. Esses quatro fatores são inter-relacionados. A maioria das compras do varejo são

feitas com base na previsão de demanda. As decisões de compra no mercado interno ou no mercado externo (Ásia) afetam diretamente o tempo de atravessamento, mas oferecem custos diferenciados, normalmente sendo menores os custos das compras no mercado externo. No entanto, quanto maior o tempo de atravessamento, mais distante o objetivo da previsão, e menor a acuracidade da mesma. Por outro lado, se o tempo de atravessamento for curto, é possível utilizar informações de demanda realizada para atualizar a previsão de demanda, atualizando as quantidades em estoque por meio de reposições. O que aumenta indiretamente a acuracidade da previsão de demanda. Segundo Mattila et al. (2002), a acuracidade da previsão de demanda nesse contexto se refere ao resultado final da estação de vendas, isto é, o quão alinhada esteve a decisão de quantidades compradas à demanda real. Não se está buscando verificar a acuracidade do modelo de previsão de demanda utilizado pelo varejista. Por isso, pode-se considerar que a redução do tempo de atravessamento possa melhorar a acuracidade da previsão de demanda.

Uma análise dos fatores propostos permite identificar sobreposições: (a) ambos concordam que previsão de demanda é necessária, e sua acuracidade é determinante; (b) ao tratarem de velocidade da cadeia de suprimentos e tempo de atravessamento do processo os autores tratam do mesmo assunto, a agilidade do sistema, que também será influenciada pelo composto de compras no mercado externo e interno; (c) o composto *offshore*/local e a composição de compra inicial e reposições têm ligação direta com o planejamento de estoques e o risco de sua operação. Dados disponíveis e confiáveis podem ser considerados como básicos para que os outros fatores possam ser gerenciados. Dessa sobreposição, podem ser resumidos quatro fatores: (a) dados disponíveis e confiáveis; (b) acuracidade da previsão de demanda; (c) planejamento de estoques; e (d) velocidade da cadeia de suprimentos. Como o modelo não considerou modificações na velocidade da cadeia, esse elemento não faz parte do modelo conceitual. Também não tratará diretamente do planejamento de estoques, mesmo que o mesmo seja diretamente influenciado pela acuracidade da previsão de demanda.

Por outro lado, Fisher (2009) sugere que os varejistas precisam definir quatro importantes questões para gerenciarem suas cadeias de suprimento: determinar qual o sortimento de produtos a ser oferecido em cada ponto de venda a cada momento ao longo do tempo, à que preço e quais as quantidades de estoque serão observadas, e estimular os funcionários a obterem a operação ou execução da loja atendendo ou superando as necessidades do negócio. O modelo conceitual não considerará o preço e a operação ou execução da loja. O autor optou por chamar essas decisões de decisões operacionais do varejo, já que não existe uma nomenclatura definida para essas questões importantes para a

operação do varejo. A decisão de quantidades de produtos a serem mantidas em estoque no ponto de venda também poderia ser chamada de planejamento de estoques. No entanto, manteve-se essa nomenclatura para que haja uma diferenciação entre a política a ser adotada para gestão dos estoques e a decisão a respeito da quantidade de produtos em si, a decisão a ser otimizada. O modelo conceitual utilizado para construção do modelo proposto pode ser visualizado na Figura 6. O objetivo é apresentar os conceitos e teorias que dão sustentação ao modelo, e como se relacionam.

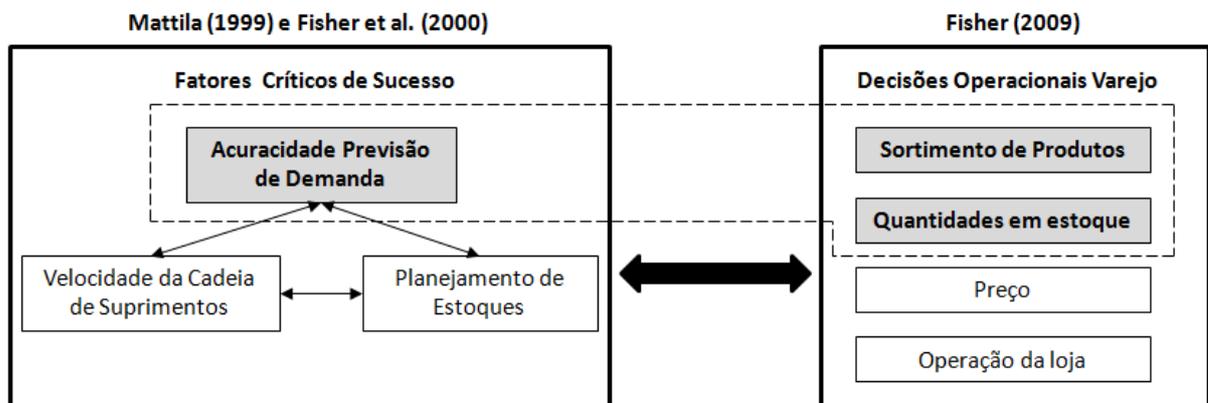


Figura 6 – Modelo conceitual

Fonte: o autor (2014)

Os fatores críticos de sucesso como definidos por Mattila (1999) e Fisher et al. (2000) têm características estruturais: são condições, características e competências desenvolvidas ao longo da cadeia de suprimentos de determinado varejista. Já as decisões operacionais que o varejista precisa tomar, obviamente, são decisões, tomadas com base nas restrições e possibilidades que a cadeia de suprimentos e o negócio do varejista proporcionam ao mesmo – entre eles os fatores críticos de sucesso. Como já mencionado, existem dentro de cada grupo relações e realimentações, e existem também relações e realimentações entre os grupos. Tanto é que as informações obtidas do sistema de previsão de demanda são utilizados para tomada de decisão de quantidade e sortimento de produtos, e o sucesso ou não das decisões tomadas em “t” influenciará o sistema de previsão em “t+1”. Assim, o modelo proposto tem seu foco delimitado à acuracidade da previsão de demanda, às decisões de sortimento de produtos e às quantidades a serem mantidas em estoque dos produtos definidos pelo sortimento adotado.

3.3 COLETA DOS DADOS

A coleta de dados quantitativos foi realizada por meio de relatório gerados diretamente

do software de gestão da empresa em estudo. Esses relatórios foram gerados no software Microsoft Excel. Os mesmos continham dados de cada produto vendido individualmente. Ou seja, para a linha que continha a venda de um produto, também constavam a loja, a data da venda, o subgrupo de produtos, a cor, o tamanho e o preço de venda.

Para que os dados pudessem ser utilizados, os mesmos precisaram ser tabulados. A tabulação se deu em três etapas:

- Para a análise de clusters, as quantidades vendidas foram agrupados por subgrupo e por loja. As vendas foram somadas por semana. E foram coletados dados dos anos de 2011 e 2012 de oito lojas, e de três subgrupos de produtos;
- Para o modelo de longo prazo, a mesma estrutura de tabulação foi adotada. No entanto, foram utilizados também dados de 2010 e 2013. E quanto à amostra, foram selecionadas somente três lojas por meio da análise de aglomerados, o que será descrito posteriormente.
- Já para o modelo de curto prazo a tabulação se deu a por combinação de produto e cor. Foram somadas as quantidades de produtos vendidas por combinação para cada semana de venda dos produtos do subgrupo de produtos escolhido, como será descrito posteriormente. Sendo que as vendas foram filtradas também por loja. Foram coletados dados de 11 diferentes produtos e 50 combinações de produto e cor. Na estação, foram comercializados 67 modelos e 227 combinações. Foram analisados produtos de 5 semanas, dentre as 23 semanas desde o início da coleção até o final do ano.

Já as informações coletadas dentro do paradigma qualitativo a respeito do sistema em estudo foram obtidas por meio de observação não sistemática. Como o pesquisador trabalha em uma das empresas fornecedoras de calçados para a empresa varejista, o conhecimento foi sendo gerado ao longo do tempo sem planejamento e sistematização. Pequenas dúvidas foram dirimidas com questionamentos diretos aos responsáveis por compras, estilo e estratégia do varejista.

3.4 ANÁLISE DOS DADOS

A análise dos resultados buscou analisar o desempenho do modelo proposto e, quando possível, compará-lo com o modelo utilizado pela empresa. Além disso buscou identificar

fragilidades e potenciais do modelo proposto, bem como implicações gerenciais associadas à utilização do modelo tendo como base o modelo teórico.

A análise dos resultados da análise de aglomerados foi realizada via teste ANOVA. Dentre as combinações de variáveis, a de melhor desempenho foi definida. Esse teste compara as médias dos valores das variáveis de cada aglomerado resultante. A comparação verificou se é possível ou não afirmar que existem diferenças entre as médias com confiabilidade estatística. Assim, a combinação de variáveis que obteve melhor desempenho em termos p-valor nos testes foi considerada.

A análise de desempenho preditivo da previsão de longo prazo se deu por meio das métricas MAPE (média absoluta percentual dos erros) e MSE (erro médio quadrático). Como não existe um modelo de previsão original, os modelos gerados não poderão ser comparados diretamente. Nessa situação, serão considerados melhores os menores valores de cada métrica, já que para elas quanto menor, melhor. A métrica MAPE, por ser mais intuitiva, foi utilizada como principal critério de avaliação do modelo. Ela é mais intuitiva pois indica um percentual comparável entre previsões de diferentes valores. Também será utilizada a comparação da APE entre a previsão de todo o período e a demanda realizada em todo o período. Essa métrica busca verificar quão precisa está a quantidade comprada para toda a estação. Isso se justifica porque é mais interessante para um varejista que haja uma pequena sobra de produtos do que uma pequena falta. A perda de ganho é maior do que a perda que é compensada pela liquidação (MATILLA, 1999).

A medição do desempenho das previsões realizadas pelo modelo foi realizada com base nos critérios MAPE* (média absoluta percentual dos erros ajustada) e APE (erro absoluto percentual). O MAPE* será utilizado porque foram observadas semanas com venda zero. Se a métrica MAPE (média absoluta percentual dos erros) fosse utilizada, isso geraria um viés nos resultados observados. Assim seria porque as semanas com vendas zero precisariam ser descartadas para que a métrica obtivesse resultado matematicamente possível, já que não é possível dividir um número por zero, como é necessário para essa métrica. E descartar essas semanas faria com que resultados importantes, quando a venda é extremamente baixa, não fossem considerados. Isso iria contra o problema e os objetivos do trabalho. Somada a essa métrica, o APE foi utilizado porque, atualmente, a principal informação para os gestores da rede no que se refere a desempenho é o quanto a previsão foi acertada como um todo. Essa métrica soma todos os valores previstos e realizados e os analisa como se fossem somente um evento. A métrica APE não é sensível às oscilações durante as semanas de venda, somente compara a venda total prevista e a venda total realizada. Já o

MAPE* é sensível à quanto a previsão a cada semana dentro do horizonte considerado estará correta. Caso a previsão estivesse prevista para o início e viesse a ocorrer no final, mesmo que a quantidade total estivesse certa, o MAPE* não geraria uma métrica mínima. Assim, as duas métricas permitem análises complementares, por isso foram adotadas. E para ambas as métricas, quanto mais próximo de zero for seu valor, melhor a métrica.

Os resultados verificados foram comparados com os resultados já indicados pela bibliografia pesquisada. E então foram discutidas as implicações gerenciais da adoção do modelo de previsão de demanda ora proposto. Para tanto, os elementos identificados no modelo conceitual foram analisados. Tanto considerando melhorias individualmente quanto considerando o impacto de melhorias nos outros elementos, já que os elementos identificados se interrelacionam. E em especial, a melhoria na acuracidade da previsão de demanda.

4 MODELO DE PREVISÃO DE DEMANDA PROPOSTO

O modelo de previsão de demanda proposto foi construído em três etapas: a escolha dos objetos de análise utilizando análise de aglomerados; o modelo de previsão de demanda de longo prazo; e o modelo de previsão de demanda de curto prazo. Eles serão apresentados nessa ordem.

4.1 ANÁLISE DE AGLOMERADOS

Conforme Fisher e Rajaram (2000) e Mostard et al. (2011), a melhor maneira de aglomerar lojas para realização de testes e previsões de demanda é de acordo com o comportamento de suas vendas. Questões relativas a tamanho, localização e características econômico-culturais da circunvizinhança são menos importantes do que o desempenho das vendas em si. Aparentemente, o que mais influencia o desempenho das vendas são as condições climáticas, mas essas já estão representadas no comportamento das vendas. A utilização de aglomerados busca simplificar o método e torná-lo mais eficiente, já que o número de análises pode ser reduzido.

A análise de aglomerados é uma técnica multivariada em que o pesquisador busca uma estrutura que explique observações compostas por múltiplas variáveis. O objetivo é classificar uma amostra de entidades (indivíduos ou objetos) em um número menor de grupos mutuamente excludentes. A classificação é feita segundo relações entre os objetos agrupados. Isso para que objetos do mesmo grupo sejam parecidos entre si e diferentes dos objetos dos outros grupos, maximizando a homogeneidade dentro do grupo e a heterogeneidade entre grupos. A técnica não é exata e existem métodos de aglomeração que não são suportados por processo estatístico rigoroso. Deste modo, é importante a avaliação e validação dos resultados pelo pesquisador, segundo o interesse da pesquisa (HAIR JR. et al., 2009).

A medição de similaridade entre casos pode ser feita por medidas de correlação, de distância ou de associação. As primeiras usam coeficientes de correlação entre os perfis e reúnem casos com perfis semelhantes, mas que podem ter valores muito diferentes. As medidas de distância reúnem casos próximos, mesmo com perfis diferentes. Uma medida é a distância euclidiana, obtida pela soma do quadrado das diferenças entre variáveis. Outras medidas de distância são a *city-block* (de Manhattan), que é a soma das diferenças absolutas das variáveis, a distância de Malahanobis, que padroniza distâncias tomadas em diferentes unidades, e a Distância de Chebychev, onde a distância é a maior diferença ao longo de todas

as variáveis de agrupamento. As medidas de associação, por sua vez, são usadas em objetos descritos por variáveis categóricas e oferecem a medida de quanto os objetos concordam ou discordam entre si, segundo as categorias de descrição (HAIR JR. et al., 2009).

Os processos de aglomeração podem ser hierárquicos ou não hierárquicos. Os primeiros constroem dendogramas (gráfico em árvore, demonstra graficamente como os agrupamentos são combinados), por procedimentos aglomerativos e divisivos. Nos aglomerativos, cada objeto começa isolado e vão se formando aglomerados por agrupação de objetos, até que haja um único aglomerado. Cinco algoritmos aglomerativos são os mais usados: (i) ligação individual; (ii) ligação completa; (iii) ligação média; (iv) método de Ward; e (v) método do centroide. Um procedimento divisivo começa com todos os objetos agrupados em um único aglomerado. Os objetos diferentes vão saindo, até que cada objeto pertença a um único aglomerado. Em ambos os casos, escolhe-se o número de aglomerados desejados e corta-se o processo na etapa correspondente (HAIR JR. et al., 2009).

Os processos não hierárquicos (*K-means*) designam objetos a agrupamentos, segundo o número de aglomerados a serem formados. Tipicamente, escolhe-se uma semente como o centro inicial de aglomerado, e todos os objetos dentro de uma distância de referência são incluídos. Em seguida, outra semente de aglomerado é escolhida, e a designação continua até que não reste objeto isolado. Os objetos podem ser realocados se estiverem mais próximos de outro aglomerado do que do original (HAIR JR. et al., 2009).

Na análise de aglomerados, a multicolinearidade atua como um processo de ponderação não visível para o observador, mas que afeta a análise. Isso porque cada variável é ponderada de maneira igual na análise. Se existirem conjuntos de variáveis multicolineares, sua similaridade irá afetar o resultado no sentido de que as variáveis com a mesma similaridade terão sido enfatizadas. Em função disso, se aconselha a reduzir as variáveis ao número de grupos multicolineares encontrados (HAIR JR. et al., 2009).

Para a realização da análise de aglomerados em si, a primeira etapa foi a definição do objeto de análise. Foram escolhidas as estações de verão de 2011 e 2012, bem como três subgrupos de produtos com volume de vendas representativo. Os subgrupos escolhidos foram Rasteiras, Sapatilhas e Sapatilhas de Tecido, por serem subgrupos de produto importantes para o desempenho da loja. Em seguida, foram definidas as variáveis de análise. Fisher e Rajaram (2000) utilizaram como dados para aglomeração das lojas o percentual de vendas entre os produtos escolhidos para teste. Eles partiram do pressuposto de que um produto pode ser definido como um conjunto de valores para vários atributos. Assim, se um determinado produto com atributos de valor semelhante vende um percentual em uma determinada loja, se

o percentual se mantiver o mesmo em outra loja, essas lojas pertencerão ao mesmo aglomerado. Assim, além do percentual de vendas entre cada subgrupo de produtos e o total de vendas (%Rast, %Sap, %STC), num primeiro momento foram consideradas a média do volume de vendas da coleção (μ), o desvio padrão do volume de vendas (σ), a variação percentual de vendas, representada pelo coeficiente de variação ($c.v. = \sigma / \mu$) e a mediana (M) do volume de vendas. A tabela 5 apresenta a descrição das variáveis utilizadas bem como um resumo dos seus objetivos.

Tabela 5 – Descrição das variáveis utilizadas para análise de aglomerados

Variável	Descrição	Objetivo
MÉDIA	Média de venda de cada loja	Captar o nível médio de vendas da loja.
MEDIANA	Mediana das vendas de cada loja	Como o coeficiente de variação é elevado, a mediana foi também adotada como alternativa de análise.
COEF_VAR	Coeficiente de Variação	O coeficiente de variação foi adotado como medida da variação das vendas ao longo da estação.
%RAST	Percentual de venda de rasteiras pela venda total	Os percentuais de venda foram adotados por apontarem comportamentos específicos em termos de volume de vendas, conforme sugerido por Fisher e Rajaram (2000).
%SAP	Percentual de venda de sapatilhas pela venda total	
%STC	Percentual de venda de sapatilhas de tecido pela venda total	

Fonte: o autor (2013)

Para evitar a multicolinearidade, foram realizadas análises de correlação entre as variáveis. As variáveis com correlação maior que 0,8 foram então utilizadas de maneira separada em cada análise. Quanto ao tamanho da amostra, foram consideradas todas as lojas com dados disponíveis no período estudado, consistindo em aproximadamente 23% da população (oito de trinta e cinco).

Então foram coletados dados de venda das últimas duas estações de Verão visando a definição de *clusters* (aglomerados) entre as lojas. Para que a análise de aglomerados pudesse ser feita, foram utilizadas as ferramentas de aglomeração de dados do *software* SPSS. Na primeira etapa da análise, foi utilizada a análise de *cluster* hierárquico. Os testes respeitaram as restrições identificadas pela análise de regressão. As restrições limitaram as variáveis a serem testadas simultaneamente, para evitar multicolinearidade. A análise de *cluster* hierárquico foi feita para identificar via dendograma a quantidade de grupos alcançada. E para tanto, as aglomerações sugeridas foram contadas diretamente no dendograma, na primeira aglomeração da árvore. Num segundo passo, a análise de *cluster* de K médias (algoritmo *k-*

means) foi utilizado com o número de aglomerações identificadas no passo anterior. Dentre as combinações de variáveis, a de melhor desempenho foi definida via teste ANOVA. Dentre os aglomerados identificados, foram escolhidos dois para aplicação do modelo de previsão de longo prazo. Em um dos aglomerados, duas lojas foram escolhidas para que os resultados pudessem ser comparados dentro do aglomerado.

4.2 PREVISÃO DE LONGO PRAZO

Correa (2007), em trabalho realizado junto à empresa varejista espanhola Zara, desenvolveu um método de previsão de demanda para uma realidade semelhante à verificada na empresa objeto de estudo do trabalho. Esse modelo foi utilizado como parte de um projeto de reengenharia do processo de distribuição da Zara, obtendo bons resultados (CARO; GALLIEN, 2010; CARO et al., 2010). O modelo de previsão de demanda considerou que as quantidades demandadas para cada grupo de produtos se manteria igual a cada semana do ano. Ou seja, independentemente do modelo sendo vendido, a soma total das vendas do grupo de produtos deve manter-se dentro de um valor previsível. A mesma ideia é suportada por Zotteri et al. (2005), considerando a lógica de previsões agrupadas por grupos de produtos. No entanto, o objetivo do modelo de previsão de Correa (2007) tinha como horizonte de previsão somente uma semana, e pressupõe revisões semanais. Ele utilizou a proporção entre as vendas das semanas subsequentes como uma variável de tendência (aumento ou diminuição).

Para a empresa objeto de estudo do presente trabalho, a previsão de vendas é realizada de maneira subjetiva antes da compra de cada entrada de produtos. O planejamento de vendas da estação é decomposto por grupo e subgrupo de produtos. Então, produtos para cada faixa de preço são escolhidos para cada entrada mensal de produtos. Espera-se que a quantidade comprada seja vendida totalmente em seis semanas, sendo essa a cobertura de estoques estimada. Assim, de maneira simples, pode-se deduzir que a previsão de demanda semanal é a quantidade comprada dividida pelo número de semanas até onde se espera que haja cobertura de estoques, ou seja, seis. No entanto, essa previsão é uma previsão de curto prazo, por produto, não de longo prazo. O aumento de vendas que existe ao final do ano é notável. Para atender esse aumento de demanda, parte da ação se dá pelo aumento da quantidade comprada por produto, parte pelo aumento do número de produtos comprados.

Correa (2007) considerou em seu modelo a quantidade de itens sendo vendidos por grupo de produtos para decompor a quantidade total do grupo para cada produto em si. No

entanto, ele não considerou as quantidades vendidas nos anos anteriores no seu modelo, somente a quantidade atual para ponderação. Para o modelo ora proposto, o horizonte de análise é maior. Assim, a compensação do aumento de volume de vendas do final do ano feita com o aumento do número de modelos precisa ser levada em consideração. Caso contrário, haveria uma superestimação da demanda do final do ano.

No presente trabalho, para identificar a previsão de demanda de longo prazo foi identificado o modelo que melhor se adéqua aos dados históricos. No *software* CurveExpert, foram realizadas regressões lineares e não lineares para identificar o modelo de melhor adequação. As séries de vendas semanais de cada ano foram submetidas individualmente à regressões lineares e não lineares. O *software* CurveExpert utiliza o método Levenberg-Marquardt para resolver as regressões não lineares. A escolha do modelo a ser utilizado foi feita também com base nos resultados indicados pelo *software*. Buscou-se utilizar o mesmo modelo para os modelos de todos os subgrupos. Após a definição dos parâmetros do modelo selecionado para cada subgrupo de produtos, esses parâmetros foram utilizados para gerar a previsão de demanda para cada semana do ano no *software* Microsoft Excel. Os valores do modelo de previsão final para cada subgrupo foram obtidos da média ponderada dos valores dos modelos individuais de 2010, 2011 e 2012. Coeficientes foram arbitrados para ponderar a importância de cada modelo. Baseando-se na lógica de que quanto mais recente a previsão, maior a probabilidade de ela estar correta. Os valores dos coeficientes se encontram na Tabela 6. Nota-se que a importância de cada modelo diminui pela metade a cada ano.

Tabela 6 – Coeficientes arbitrados para ponderação da média da Previsão de Longo Prazo

ANO	COEFICIENTES ARBITRADOS
2010	14,28%
2011	28,57%
2012	57,14%

Fonte: o autor (2013)

Como foi escolhida a estação de verão para ser analisada, no modelo ora proposto a semana 1 em análise foi a semana 27 do ano. A semana 26 da análise não foi prevista por meio do modelo escolhido. Em função da forma como os dados foram recebidos, terminando no dia 31 do ano em análise, foi necessário adotar uma abordagem diferente para ajustar a previsão da mesma. Como as vendas dessa semana foram consideráveis, escolheu-se não desprezar essa semana. Para os anos de 2010 e 2011, a semana 26 foi a última semana do ano, sendo que em 2010 teve 6 dias e 2011 teve 7 dias. Para 2012 e 2013 houve mais um e dois

dias respectivamente no ano, na semana 27. Para 2010, 2011 e 2012 foi calculada então a razão entre a venda da semana 26 e 26+27 pela venda das quatro semanas anteriores. Esse percentual foi dividido pelo número de dias das semanas 26 e 26+27 obtendo-se assim um percentual entre a venda de cada dia dessas semanas e as vendas das quatro semanas anteriores. Assim, o valor previsto da venda para a semana 26 para o ano de 2013 foi a soma da venda prevista das semanas 22, 23, 24 e 25 multiplicado pelo percentual final obtido. Esse percentual foi obtido pela multiplicação do percentual diário pelo número de dias da semana 26+27 de 2013.

Por se tratar de uma série temporal, a previsão de vendas de longo prazo será função somente da semana, verificada na Equação 12:

$$\text{Previsão de Vendas Longo Prazo} = f(\text{semana}) \quad (12)$$

E espera-se encontrar uma série temporal, em princípio não linear, devido à ocorrência de fatores que podem acelerar ou retardar as vendas ao longo do período, tal como proximidade de datas festivas ou remuneração natalina dos trabalhadores.

Da mesma forma que o modelo de Correa (2007) utilizou a informação de longo prazo, o modelo de previsão de longo prazo ora apresentado será uma variável de tendência (aumento ou diminuição) para o modelo de previsão de curto prazo. Para isso, Correa (2007) utilizou a proporção entre as vendas das semanas subsequentes. No entanto, além da variação sazonal, para o modelo ora proposto existe uma variação no número de produtos disponíveis para venda. Essa variação gera uma variação no volume de vendas do subgrupo de produtos sem necessariamente haver aumento da venda de qualquer produto pertencente ao subgrupo. Então, para que essa informação fosse transmitida de um modelo para o outro foi necessário criar uma variável que dependesse tanto da quantidade prevista pelo modelo de longo prazo quanto da quantidade de modelos sendo ofertados. Para isso, foi criada a variável Razão de Incremento Semanal (RIS). Essa variável é obtida a partir de outras duas variáveis: a quantidade de produtos vendidos por semana (prevista ou real) e a quantidade de modelos (considerando as variações de cor) vendidos por semana (previsto ou real). A razão das duas variáveis dá origem à RIS. Para diferenciar a entre uma RIS prevista e uma RIS real, a RIS prevista será chamada de RIS*. A razão de incremento semanal pode ser verificada na equação 13:

$$RIS = \frac{QPVS}{QMVS} \quad (13)$$

onde:

RIS = Razão de incremento semanal

QPVS = Quantidade de Produtos Vendidos por Semana

QMVS = Quantidade de Modelos Vendidos por Semana

Foram coletadas as quantidades de modelos vendidos (considerando a cor) por semana dos anos 2011 e 2012. A quantidade prevista para cada semana de 2013 foi a média ponderada de 2011 e 2012, sendo que 2011 teve 33,33% de peso e 2012 teve 66,66%. Assim, a *RIS* foi obtida pela divisão da quantidade real de produtos vendidos por semana de 2013 pela quantidade real de modelos vendidos por semana em 2013. Já a *RIS** foi obtida pela quantidade de produtos vendidos prevista pelo modelo de longo prazo para cada semana dividida pela média ponderada de modelos vendidos dos anos de 2011 e 2012.

Nota-se que tanto o planejamento da rede de varejo como o modelo de previsão ora proposto são do tipo *top-down* (de cima para baixo). O planejamento é realizado considerando todos os produtos e subprodutos de maneira agregada (ZOTTERI et al., 2005). Obviamente, em função de realizar a previsão antes da previsão de vendas ele é *a priori* (MOSTARD; TEUNTER; DE KOSTER, 2011).

4.3 PREVISÃO DE CURTO PRAZO

De maneira semelhante a Correa (2007), a desagregação da previsão de vendas de grupo de produtos para o nível de modelo e cor será realizada com base nos dados coletados *a posteriori*. O modelo de Correa (2007) considera a venda de cada produto à cada semana para prever a próxima semana, levando em consideração o estoque disponível. Mas principalmente considera a quantidade de produtos que o lote de reposição que chegará à loja terá. Isso porque o objetivo final do modelo de previsão era a determinação ótima dessa quantidade. O modelo ora proposto não considera reposições para realizar a previsão de demanda. Além disso, existe o interesse de obter informações quanto à demanda o mais rápido possível, para que haja tempo de tomar atitudes. Atitudes essas que podem ser, todavia, reposições de produtos populares. Assim, a primeira semana de vendas de cada produto será considerada para a previsão. Ela definirá a proporção das vendas por semana por modelo e cor. Pressupõe-

se que a quantidade vendida por grupo de produto nas semanas posteriores se manterá dentro do que ocorreu no ano anterior em termos de quantidade (modelo matemático) e de venda por produto e cor (média de produtos vendidos) para o subgrupo de produtos, e também dentro da proporção de quantidade vendida verificada entre o produto e seu subgrupo. Essa é a forma que a previsão de longo prazo influencia a decomposição da previsão agregada (*a priori*) para a previsão desagregada (*a posteriori*).

A Figura 7 mostra a metodologia do modelo de previsão ora proposto.

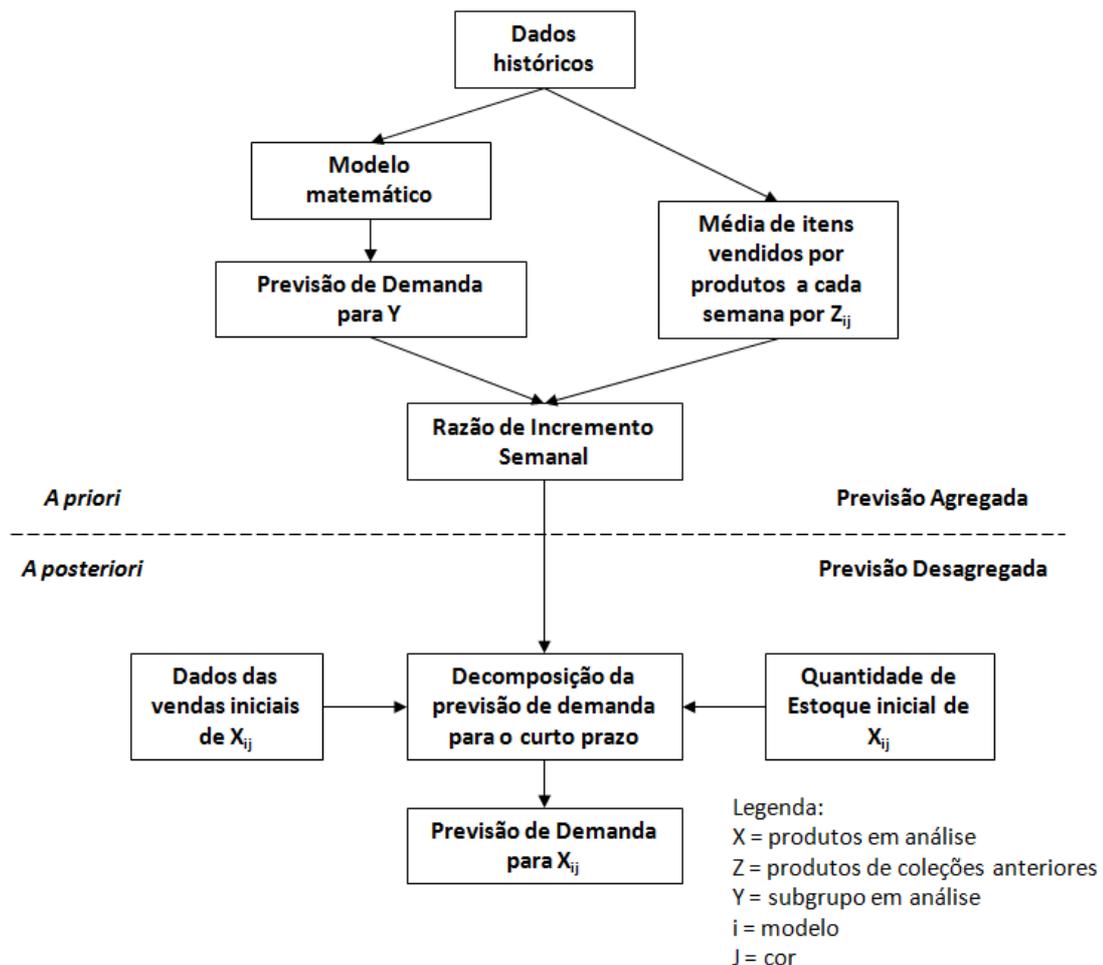


Figura 7 – Metodologia do modelo de previsão de demanda

Fonte: o autor (2013)

A primeira etapa do modelo de previsão de demanda proposto é a coleta de dados. Os dados históricos de quantidade vendida, por semana, por cada subgrupo de produtos e por loja das estações anteriores são coletados e alimentam o modelo de previsão de demanda de longo prazo, já anteriormente detalhado. O modelo gera uma previsão de demanda para cada subgrupo de produtos Y de cada loja, por semana. Por outro lado, os dados da média de itens vendidos por produtos Z_{ij} a cada semana das estações anteriores são coletados. A divisão da

quantidade prevista pela média de itens vendidos por produto da origem a RIS. Então, após o início da estação de vendas, os dados das primeiras semanas de venda de cada produto X_{ij} individualmente são coletados. Esses dados, a RIS e a quantidade do estoque inicial são os dados de entrada para a decomposição da previsão de demanda para o curto prazo, que da origem à previsão de demanda para X_{ij} para cada semana ou segundo o horizonte demandado, no caso em questão, seis semanas.

Considerando que o período planejado de vendas é de seis semanas, caso o estoque de uma combinação de cor de um produto terminar antes desse intervalo de tempo, isso afetará a demanda dos demais itens. A demanda antes direcionada para esse item será destinada para outros itens ou não será atendida, gerando uma demanda de substituição. Além disso, antes mesmo do término do estoque de um SKU já se nota uma diminuição de sua demanda (CARO; GALLIEN, 2010; CORREA, 2007). Isso acontece porque os tamanhos mais populares acabam antes e é chamado por varejistas de calçados de “quebra de grade” ou “grades quebradas”. Assim, a partir da Equação 14 pode-se dizer que a previsão de vendas de curto prazo é função de:

$$\text{Previsão de Vendas Curto Prazo} = f(\text{RIS; VPS; EI; QG; DS}) \quad (14)$$

onde:

RIS = Razão de incremento semanal

VPS = Vendas da primeira semana

EI = Estoque Inicial

QG = Quebra de grade

DS = Demanda de substituição

A relação entre o RIS, a VPS, o EI e o conceito de cobertura de estoques é que são a base para esse modelo de previsão. Conforme Dias (2009), a taxa de cobertura é igual ao estoque médio dividido pelo consumo. Segundo Martins e Alt (2009), a cobertura de estoques indica o número de unidades de tempo (dias, meses, etc.) em que o estoque médio irá cobrir a demanda média, sendo que, para esses autores, a cobertura de estoques é igual ao número de unidades de tempo dividido pelo giro de estoque. Para Ballou (2006), o giro de estoques é o resultado da divisão das vendas anuais ao custo de estoque pelo investimento médio em estoque, levando-se em conta o mesmo período das vendas. Já para Dias (2009), a rotatividade ou giro do estoque é a relação entre o consumo anual e o estoque médio do

produto, ou seja, a rotatividade é igual ao consumo médio anual dividido pelo estoque médio.

Se somente a VPS e o EI fossem considerados, a cobertura de estoque para o período seria a divisão de EI por VPS, e ter-se-ia a cobertura de estoques em semanas. Esse indicador é utilizado pela rede atualmente, mas seu resultado considera um comportamento linear, não considerando a sazonalidade. O RIS indicará a razão de incremento de vendas por produto, de acordo com a semana inicial de venda. Assim, a variação do RIS deve ser acompanhada pela cobertura de estoques ajustada. Para tanto, a venda da primeira semana (t) do produto em análise ($VPS_t X_{ij}$) deve ser dividida pela RIS realizada de t (obtida pela divisão da quantidade total vendida no subgrupo pelo número de produtos diferentes vendidos, considerando as combinações de cores) gerando o fator sazonal (FS) dessa combinação. O valor arredondado da multiplicação de FS pela RIS^*_{t+1} (obtida do modelo de longo prazo) e pelo coeficiente *alfa* (α), adicionado da previsão da rede para t+1 (PR_{t+1}) multiplicada por 1 menos α , será a previsão semanal simples ($YS(X_{ijt})$). Assim como verificado por Correa (2007), utilizar mais fontes de informação na previsão pode reduzir o viés na previsão. Existem situações em que a demanda da primeira semana será zero. Considerando que existe conhecimento no julgamento que gerou a previsão original, uma parte dessa previsão será utilizada. Isso porque dificilmente o produto não venderá nenhum item. Para isso que foi utilizado o coeficiente α . Se α for 1, somente a previsão obtida pela multiplicação de FS por RIS^* será utilizada. Se α for 0, somente a previsão original será adotada. As equações podem ser verificadas nas Equações 15 e 16.

$$FS = \frac{VPS_t X_{ij}}{RIS_t} \quad (15)$$

$$YS(X_{ijt}) = ARR(FS * RIS^*_{t+1} * \alpha + PR_{t+1} * (1 - \alpha)) \quad (16)$$

onde:

FS = Fator Sazonal

$VPS_t X_{ij}$ = Vendas da Primeira Semana t do produto X_{ij}

RIS_t = Razão de Incremento Sazonal realizada de t

RIS^*_{t+1} = Razão de Incremento Sazonal prevista de t+1

PR_{t+1} = Previsão original da Rede para t+1

$YS(X_{ijt})$ = Previsão de vendas Simples para o produto X_i , na cor j, na semana t

A Tabela 7 apresenta um exemplo de como a previsão é gerada, para o modelo RT0197 na cor acqua. Na primeira semana de vendas, a 19, o produto vendeu 1 par. Essa quantidade deve ser dividida pela RIS realizada na semana 19 de 2013 (3,19) gerou um FS de 0,319. Assim, a previsão simples para t+1 (20) foi obtida de acordo com a Equação 16, resultando em 2. O mesmo procedimento da Equação 16 foi repetido para as demais semanas, t+2 até t+7.

Tabela 7 – Previsão de vendas simples do produto RT 0197 cor acqua

MODELO	19	20	21	22	23	24	25	26	EI	FS
RT 0197 - ACQUA	1								32	0,319
PREVISÃO SIMPLES		2	2	2	2	3	4	3		
RIS 2013	3,19									
RIS* 2013		4,37	4,97	5,35	6,27	8,54	12,4	8,99		

Fonte: o autor (2014)

No entanto, o estoque inicial é uma restrição da previsão, já que esse é um dado conhecido. Por isso, caso o valor previsto para a semana somado ao valor da primeira semana e das previsões das outras semanas já previstas seja maior que o Estoque Inicial (EI), a verificação de estoque mudará o valor para zero. Tal verificação é feita pela utilização da função condicional “SE” no Excel. Essa função é baseada no conceito “IF-THEN”, utilizado também pela lógica difusa. Essa lógica é expressa na Equação 17. Caso a soma da venda da primeira semana com as previsões até a ultima semana antes da semana em análise sejam maiores que o EI, ela deve se converter em 0. Caso contrário, segue a previsão de vendas simples. Para melhor entendimento da construção da função “SE” do Excel, sua lógica é demonstrada na Equação 18.

$$Yse(X_{ijt+a}) = SE(VPS_t X_{ij} + \sum_{t=i}^{t=a-1} Yse X_{ijt} > EI; 0; ARR(FS * RIS^*_{t+a} * \alpha + PR_{t+a} * (1 - \alpha))) \quad (17)$$

onde:

$Yse(X_{ijt+a})$ = Previsão de Demanda considerando o estoque

t=a = Semana em análise

t=i = Semana inicial de análise

$$=SE(teste_lógico; valor_se_verdadeiro; valor_se_falso) \quad (18)$$

A Tabela 8 apresenta essa situação para o produto RT0194 na cor bronze. Nela se pode notar que após quatro semanas o valor foi reduzido para zero em função do término do estoque.

Tabela 8 – Verificação de estoque na previsão do produto RT 0194 cor bronze

MODELO	19	20	21	22	23	24	25	26	EI	FS
RT 0194 - BRONZE	5								32	1,568
PREVISÃO SIMPLES		7	7	8	9	12	17	12		
VERIFICAÇÃO DE ESTOQUE		7	7	8	9	0	0	0		
RIS 2013	3,19									
RIS* 2013		4,37	4,97	5,35	6,27	8,54	12,4	8,99		

Fonte: o autor (2014)

Kok e Fisher (2007) consideraram a demanda de substituição em sua pesquisa. Eles consideraram que a demanda observada de um produto é a demanda real adicionada da demanda de substituição em função da falta de estoque de outro produto. Para o caso em questão, não existem dados suficientes para realizar a estimativa do percentual de demanda de substituição como sugerido pelos autores. No entanto, Mattila (1999) observou que nos casos de faltas de estoque em sua pesquisa, 40% da demanda potencial foi perdida e 60% foi redirecionada como demanda de substituição para outros produtos.

Kok e Fisher (2007) sugerem três situações em que podem ocorrer demandas de substituição: (a) substituição em função da falta de produtos em estoque, e ele adquire outro produto diferente; (b) substituição baseadas no sortimento de produtos, quando ele não encontra o produto desejado naquela loja específica e compra um semelhante; e (c) quando um determinado produto não está exposto, seria o escolhido pelo consumidor, mas por não estar disponível para visualização o consumidor adquire outro produto. Considerando as variáveis e as possibilidades de maneira simplificada, é possível identificar quatro grupos de possibilidades no presente estudo, referentes à condição de faltas de estoque de um produto de determinada cor:

- A possibilidade de o cliente comprar o mesmo modelo, em outra cor;
- A possibilidade de o cliente comprar outro modelo, do mesmo grupo de produtos;
- A possibilidade de o cliente comprar outro modelo, mas de outro grupo de produtos; e
- A possibilidade de o cliente não realizar nenhuma compra.

Em função das restrições verificadas de não conhecer quais produtos estarão sendo ofertados nas seis semanas subsequentes, somente a primeira das possibilidades gerará demanda de substituição para o modelo ora proposto. Assim, no presente modelo será considerada como taxa de demanda de substituição 20% da demanda perdida, um terço do observado por Mattila (1999). Esse percentual será transferido para o modelo pelo coeficiente *gama* (γ), de 0,2, que será multiplicado pela demanda perdida por não existirem os itens em estoque.

Para operacionalizar esse conceito no modelo, foram necessárias três etapas no *software* Excel. O primeiro passo foi verificar se entre as verificações de estoque das outras cores do produto alguma chegou à zero. A função condicional “SE” do Excel permitiu essa situação, e as demandas prováveis que não seriam atendidas foram somadas nesse passo. A Equação 19 demonstra esse passo.

$$\sum DP_t = \sum_{j=i+1}^{j=n} SE(VPS_t X_{ij} + \sum_{t=i}^{t=a} Yse X_{ijt} > EI_j; Yse X_{ijt=a} - EI; 0) \quad (19)$$

onde:

$\sum DP_t$ = Somatório da Demanda Perdida para a semana t em análise

t=a = Semana em análise

t=i = Semana inicial de análise

O passo seguinte foi somar a previsão simples de todas as cores que ainda tinham itens em estoque. Isso foi necessário para criar uma lógica de divisão da demanda de substituição entre as cores. Caso um produto tivesse demanda e não tivesse itens em estoque, não se poderia somar 20% dessa demanda a todos os produtos. Se fossem dez outras cores, isso geraria uma demanda duas vezes maior que a perdida. Por isso, os 20% precisam ser divididos entre as cores que ainda tem itens em estoque. A Equação 20 apresenta o segundo passo.

$$\sum PIE_t = \sum_{j=1}^{j=n} SE(EI \neq 0; Yse(X_{ijt})); 0) \quad (20)$$

onde:

$\sum PIE_t$ = Somatório de Produtos com Itens em Estoque para a semana t

A lógica escolhida para dividir a demanda de substituição entre as combinações que ainda tivessem estoque foi ponderar a divisão dos 20% de acordo com a demanda prevista para a semana para cada cor. Assim, a demanda da semana de uma cor individualmente foi dividida pelo total demandado pelas cores que ainda possuíam itens em estoque. O resultado dessa divisão será o percentual dos 20% que serão somados à demanda daquela cor, no terceiro passo. A Equação 21 apresenta esse passo.

$$Y_{sub}(X_{ijt}) = ARR \left(SE \left(\sum DP_t \times \sum PIE_t = 0; Y_{se}(X_{ijt}); \gamma \times \frac{Y_{s}(X_{ijt})}{\sum PIE_t} \times \sum DP_t + Y_{se}(X_{ijt}) \right) \right) \quad (21)$$

onde:

$Y_{sub}(X_{ijt})$ = Previsão de Vendas considerando a demanda de substituição para a semana t

A Tabela 9 demonstra um exemplo para o produto RT0194 na cor preta.

Tabela 9 – Demanda de substituição na previsão do produto RT 0194 cor preta

MODELO	19	20	21	22	23	24	25	26	EI	FS
RT 0194 - PRETO	2								40	0,627
PREVISÃO SIMPLES		4	4	4	4	6	8	6		
VERIFICAÇÃO DE ESTOQUE		4	4	4	4	6	8	6		
Σ DEMANDA PERDIDA		0	0	0	0	12	17	12		
Σ DEMANDA SIMPLES TOTAL		31	34	35	37	33	42	36		
PREVISÃO + DEMANDA SUBS.		4	4	4	4	8	11	8		
RIS 2013	3,19									
RIS* 2013		4,37	4,97	5,35	6,27	8,54	12,4	8,99		

Fonte: o autor (2014)

Além desse fenômeno, a quebra de grade gera uma redução da demanda mesmo com a existência de produtos em estoque. Assim, sempre que a quantidade em estoque se aproximar de zero, a demanda do produto em questão será diminuída em um determinado percentual. É importante considerar que as grades de compra de calçados consideram a distribuição de consumo por tamanho, carregando mais os tamanhos mais comuns, mais centrais. Assim, quando a quantidade em estoque for menor que nove pares, a demanda considerada pelo

modelo será reduzida para 30% do previsto. Esse percentual foi definido de maneira empírica. Para tanto, se utilizou o coeficiente β de 0,3.

Na última etapa, além da quebra de grade, são feitas outras verificações. Utilizando uma combinação da função condicional “SE”, num primeiro momento verifica-se se a quantidade vendida na primeira semana somada às quantidades previstas para as semanas anteriores mais a demanda de substituição nas semanas anteriores é maior do que a quantidade em estoque, novamente. Se for, o valor previsto é zero, já que não existiriam produtos em estoque. Numa segunda condição, verifica-se se a soma da venda da primeira semana, dos valores previstos para as semanas anteriores adicionada da demanda de substituição e mais a previsão para a semana em análise é maior que a quantidade inicial em estoque. Se for maior, a previsão será o estoque inicial diminuído da soma da quantidade vendida na primeira semana e das quantidades previstas para as semanas anteriores mais a demanda de substituição. Numa terceira condição, caso a quantidade vendida na primeira semana somada às quantidades previstas para as semanas anteriores mais a demanda de substituição for maior do que o estoque inicial menos nove, a previsão da semana em análise será multiplicada pelo coeficiente β . Caso nenhuma das condições anteriores seja atendida, a previsão do modelo será igual a previsão da linha anterior sem alterações. A Equação 22 apresenta a etapa final.

$$Y(X_{ijt}) = ARR \left(SE \left((VPS_t X_{ij} + \sum_{t=i}^{t=a-1} Y(X_{ijt})) > EI; 0; SE \left((VPS_t X_{ij} + \sum_{t=i}^{t=a-1} Y(X_{ijt}) + Y_{sub}(X_{ijt=a})) > EI; EI - (VPS_t X_{ij} + \sum_{t=i}^{t=a-1} Y(X_{ijt}) + Y_{sub}(X_{ijt=a})); SE \left((VPS_t X_{ij} + \sum_{t=i}^{t=a-1} Y(X_{ijt}) + Y_{sub}(X_{ijt=a})) > EI - 9; \beta \times Y_{sub}(X_{ijt}); Y_{sub}(X_{ijt}) \right) \right) \right) \right) \quad (22)$$

onde:

$Y(X_{ijt})$ = Previsão de Demanda para o Produto X_i na cor j na semana t

$\sum_{t=i}^{t=a-1} Y(X_{ijt})$ = Somatório das Previsões de Demanda das semanas anteriores

Um exemplo para o produto RT0194 na cor preta se encontra na Tabela 10.

Tabela 10 – Quebra de grade e modelo final na previsão do produto RT 0194 cor preta

MODELO	19	20	21	22	23	24	25	26	EI	FS
RT 0194 - PRETO	2								40	0,627
PREVISÃO SIMPLES		4	4	4	4	6	8	6		
VERIFICAÇÃO DE ESTOQUE		4	4	4	4	6	8	6		
Σ DEMANDA PERDIDA		0	0	0	0	12	17	12		
Σ DEMANDA SIMPLES TOTAL		31	34	35	37	33	42	36		
PREVISÃO + DEMANDA SUBS.		4	4	4	4	8	11	8		
MODELO		4	4	4	4	8	11	3		
RIS 2013	3,19									
RIS* 2013		4,37	4,97	5,35	6,27	8,54	12,4	8,99		

Fonte: o autor (2014)

Armstrong (2001) sugere que se comparem modelos novos e antigos, mesmo que haja pouco embasamento para os últimos. Isso para verificar se é vantajoso modificar o que está em uso para um modelo novo. Por isso, o modelo ora proposto será comparado com a previsão pelo método de julgamento por especialistas, utilizado na rede varejista.

4.4 PRESSUPOSTOS DO MODELO

Como um dos pressupostos do modelo, foi assumido que a previsão de demanda semanal de venda de um determinado produto é a compra total do mesmo por loja dividido por seis. Isso porque a cobertura de estoques prevista para cada produto pela rede de varejo, objeto de estudo da pesquisa, é de 6 semanas. Também que, apesar de serem de suma importância, a mudança dos locais dos estoques não será estudada no modelo. Por isso, pressupõem-se que o local de estoque dos produtos é sempre o estoque de cada loja individualmente.

O modelo também pressupõe que aglomerações de lojas com comportamentos de vendas semelhantes seja uma das melhores alternativas de aglomeração possíveis. Esse pressuposto também foi adotado por Fisher e Rajaram (2000). Os autores utilizaram como dados para aglomeração das lojas o percentual de vendas entre os produtos escolhidos para teste. Os mesmos partiram do pressuposto de que um produto pode ser definido como um conjunto de valores para vários atributos. Assim, se um determinado produto com atributos de valor semelhante vende um percentual da venda total em uma determinada loja, mantendo-se esse o percentual em outra loja, essas lojas devem pertencer ao mesmo aglomerado.

Com relação ao Modelo de Previsão de demanda de longo prazo, Assim como Correa

(2007), o modelo pressupõe que as quantidades demandadas para cada grupo ou subgrupo de produtos se mantém muito semelhante a cada semana do ano. Ou seja, independentemente do modelo sendo vendido, a soma total das vendas do grupo de produtos tende a se manter dentro de um valor previsível. Essa mesma ideia é suportada por Zotteri et al. (2005), considerando a lógica de previsões agrupadas por grupos de produtos. E além de pressupor o comportamento sazonal da demanda por subgrupo de produtos, o modelo também pressupõe que a quantidade de produtos comprada por o subgrupo se manterá próxima de um ano para o outro. Além disso, o modelo de previsão de longo prazo pressupõe que os anos mais recentes têm pesos maiores quando da ponderação da média do modelo final. Baseando-se na lógica de que quanto mais recente a previsão, maior a probabilidade de ela estar correta. Essa mesma lógica pode ser observada na Suavização Exponencial, onde os valores mais antigos tem menor peso na previsão. O modelo também pressupôs que os comportamentos sazonais da demanda seriam semelhantes entre os subgrupos de produtos, por isso o mesmo modelo de previsão foi adotado para todos os subgrupos de produtos analisados.

Um dos pressupostos mais importantes do modelo como um todo é que as vendas da primeira semana são fortes indicativos de como se comportará a demanda restante. Para buscar perceber isso, no modelo de previsão de curto prazo foram analisados dois horizontes de previsão: seis semanas (a inicial e outras cinco) e oito semanas (a inicial e outras sete). O horizonte de seis semanas foi adotado para testar a previsão qualitativa realizada pela rede varejista. E o horizonte de oito semanas foi escolhido para perceber se não seria melhor adotar um horizonte maior na previsão, já que, por observação, notou-se que a maioria dos produtos não terminava antes ou nas seis semanas.

Foram utilizados coeficientes para a construção dos modelo. O coeficiente α foi utilizado para ponderar no modelo final entre o modelo ora proposto e o modelo original. Sua utilização foi necessária para que não se perdessem as previsões de um produto em que a venda da semana inicial fosse zero. Se somente o modelo ora proposto fosse utilizado, a previsão do modelo seria zero para todas as semanas. Além disso, Correa (2007) também utilizou uma parcela de informação da previsão qualitativa em seu modelo e o resultado foi superior ao resultado sem a utilização dessa informação. O modelo também pressupõe que utilizar as duas fontes de informação disponíveis trará melhores resultados no geral. E o valor do coeficiente foi determinado em 0,9 para que os 0,1 que fossem utilizados do modelo original permitissem que ao menos a previsão de venda de um produto acontecesse.

Outro pressuposto do modelo é que quando a quantidade em estoque de um produto se aproxima de zero, sua demanda se reduzirá. Isso não acontece em função de uma redução da

demanda realmente, mas sim porque alguns tamanhos acabam não estando mais disponíveis. Então, mesmo havendo demanda ela não pode ser atendida. O coeficiente β foi adotado para definir o quanto haveria de redução na demanda em função disso. Os profissionais que tratam desse problema na empresa em estudo tem a percepção de que sobram normalmente os números das extremidades da grade comprada (números maiores, 39 e 40, e números menores, 33 e 34). E esses produtos acabam não sendo vendidos. Por isso, foi escolhida empiricamente uma redução de mais de 50%. O valor escolhido e avalizado por esses profissionais foi de 0,3 para β . Esse valor reduz a demanda para 30% da demanda real quando sobram menos que 9 pares em estoque. A quantidade de 9 pares foi determinada por ser a menor grade comprada pela empresa sendo estudada.

Por fim, o modelo pressupõe que a demanda observada de um produto é composta pela soma de sua demanda real à demanda de substituição de produtos que não estão mais disponíveis. Kok e Fisher (2007) utilizam esse pressuposto em seu trabalho, e sugerem um método para quantificar essa substituição. No entanto, na impossibilidade desse cálculo, por falta de informações disponíveis, adotou-se a definição de Mattila (1999). O autor observou que nos casos de faltas de estoque em sua pesquisa, 40% da demanda potencial foi perdida e 60% foi redirecionada como demanda de substituição para outros produtos. No entanto, como existem três possibilidades para a demanda de substituição ocorrer (KOK; FISHER, 2007) e somente uma delas seria considerada no modelo, os 60% foram divididos por três. Assim, o valor adotado para o coeficiente γ foi de 0,2. Isso significa que 20% da demanda perdida de uma cor que não está disponível em estoque será redistribuída entre as outras cores do modelo que está em análise.

4.5 DELIMITAÇÕES DO MODELO

O modelo de previsão de demanda ora proposto não considerará modificações em elementos descritos no modelo conceitual na sua construção e implantação: modificações na velocidade da cadeia e o planejamento de estoques. O modelo considera esses elementos como fixos, dados pelo contexto da empresa em análise. Além disso, o modelo não irá considerar modificações nos locais de estoque e preço.

Não será considerada a variabilidade do tempo de atravessamento no modelo. O modelo de previsão de longo prazo é mais suscetível à essa variação, já que atrasos ou adiantamentos no abastecimento do estoque podem mudar o momento da venda. Para o modelo de previsão de curto prazo o atraso ou o adiantamento do abastecimento é pouco

relevante numa observação direta, já que a previsão é realizada na primeira semana de venda, ou seja, com o estoque abastecido. No entanto, as variações que essa variabilidade causar no modelo de longo prazo poderão ser refletidas no modelo de curto prazo, já que ambos estão interligados.

O modelo também não fará distinção entre produtos de moda e produtos básicos. Isso principalmente porque todos os produtos são tratados de maneira igual, como de moda, pela empresa em análise.

5 APLICAÇÃO DO MODELO

Nesse capítulo serão apresentados os resultados da aplicação do modelo de previsão ora proposto, com dados reais oriundos da rede varejista cujo contexto é objeto de estudo desta dissertação. A primeira sessão tratará da análise de aglomerados realizada com objetivo de agrupar as lojas com comportamentos de vendas semelhantes, simplificando o uso do modelo. A segunda sessão tratará da aplicação do modelo de longo prazo, que buscou definir a previsão de demanda agrupada por subgrupo de produto para toda a estação de vendas. A terceira sessão apresentará o modelo de previsão de curto prazo, que utilizou dados de vendas iniciais para criar a previsão de vendas por produto e cor, baseando-se na previsão de longo prazo.

5.1 ANÁLISE DE AGLOMERADOS

A análise de aglomerados teve por objetivo agrupar as lojas com comportamentos de venda semelhantes. Esse agrupamento visa reduzir o tempo para realizar a previsão de demanda, bem como o planejamento posterior. Para tanto, foram coletadas para a estação de verão, as médias de venda, a mediana das vendas, o coeficiente de variação e o percentual de vendas de cada subgrupo no período de análise. Os valores de cada variável estão na Tabela 11.

Tabela 11 – Valores das variáveis utilizadas para análise de aglomerados

ANO	LOJA	VENDA (PARES)	DESV_PAD	COEF_VAR	MEDIANA	%RAST	%SAP	%STC
2011	1	71,51	84,50	1,18	49,50	0,5853	0,1906	0,2241
2011	2	70,08	89,92	1,28	43,00	0,5851	0,1987	0,2162
2011	3	59,08	86,78	1,47	35,00	0,6170	0,1582	0,2248
2011	4	108,67	171,52	1,58	62,00	0,6416	0,1548	0,2036
2011	5	68,14	73,63	1,08	45,00	0,5296	0,2322	0,2382
2011	6	96,76	144,04	1,49	57,50	0,6202	0,1723	0,2075
2011	7	160,29	231,33	1,44	99,00	0,5939	0,1802	0,2259
2011	8	62,29	72,65	1,17	38,50	0,5355	0,2124	0,2521
2012	1	67,36	100,93	1,50	39,00	0,5634	0,1756	0,2610
2012	2	69,84	78,70	1,13	49,00	0,4904	0,2211	0,2885
2012	3	61,64	104,55	1,70	30,00	0,5768	0,2007	0,2225
2012	4	106,36	146,85	1,38	62,00	0,5554	0,1737	0,2709
2012	5	72,46	95,72	1,32	44,00	0,5338	0,2057	0,2605
2012	6	101,26	140,32	1,39	62,00	0,5649	0,1861	0,2491
2012	7	193,81	237,44	1,23	130,00	0,4965	0,2280	0,2754

2012	8	73,93	93,86	1,27	49,00	0,5327	0,1969	0,2704
------	---	-------	-------	------	-------	--------	--------	--------

Fonte: o autor (2013)

Para evitar a multicolinearidade, foi realizada análise de correlação entre as variáveis. Foram encontradas correlações com valores maiores que 0,8 entre as variáveis. As variáveis que apresentaram essa relação não foram testadas na análise de aglomerados concomitantemente. Então, assim ficaram definidas as combinações possíveis entre as variáveis para a análise de aglomerados. Os resultados da análise de correlação estão na Tabela 12.

Tabela 12 – Análise de Correlação entre variáveis utilizadas para análise de aglomerados

		MEDIA	DESV_PAD	COEF_VAR	MEDIANA	PERC_RAST	PERC_SAP	PERC_STC
MEDIA	Correlação	1	0,962**	0,047	0,986**	-0,079	0,032	0,102
	Sig.		0	0,862	0	0,77	0,906	0,708
DESV_PAD	Correlação	0,962**	1	0,303	0,906**	0,139	-0,187	-0,062
	Sig.	0		0,254	0	0,608	0,488	0,821
COEF_VAR	Correlação	0,047	0,303	1	-0,099	0,677**	-0,706**	-0,483
	Sig.	0,862	0,254		0,715	0,004	0,002	0,058
MEDIANA	Correlação	0,986**	0,906**	-0,099	1	-0,187	0,14	0,183
	Sig.	0	0	0,715		0,488	0,606	0,498
PERC_RAST	Correlação	-0,079	0,139	0,677**	-0,187	1	-0,851**	-0,884**
	Sig.	0,77	0,608	0,004	0,488		0	0
PERC_SAP	Correlação	0,032	-0,187	-0,706**	0,14	-0,851**	1	0,507*
	Sig.	0,906	0,488	0,002	0,606	0		0,045
PERC_STC	Correlação	0,102	-0,062	-0,483	0,183	-0,884**	0,507*	1
	Sig.	0,708	0,821	0,058	0,498	0	0,045	

** . Correlação significativa em 0.01

* . Correlação significativa em 0.05

Fonte: o autor (2013)

De acordo com as restrições determinadas pelo coeficiente de correlação verificado entre as variáveis, as mesmas foram testadas simultaneamente conforme abaixo:

- MEDIA; COEF VAR; %RAST.
- MEDIA; COEF VAR; %SAP; %STC.
- MEDIANA; COEF VAR; %RAST.
- MEDIANA; COEF VAR; %SAP; %STC

Com as configurações inicialmente adotadas nenhum dos resultados verificados nas

análises de aglomerados foi significativo estatisticamente (p -valor menor que 0,05 inicialmente e menor que 0,1 em um segundo momento).

Em função das possíveis diferenças de comportamento das variáveis entre os subgrupos de produtos para cada loja, as variáveis filtradas pelos mesmos foram retestadas. As novas variáveis criadas a partir desse filtro estão na Tabela 13.

Tabela 13 – Variáveis utilizadas para a segunda análise de aglomerados

SUBGRUPO	ANO	LOJA	MÉDIA	DESV_PAD	COEF_VAR	MEDIANA	%VENDA
1	2011	1	125,58	126,18	1	61	0,5853
1	2011	2	123	138	1,12	60	0,5851
1	2011	3	109,35	135,02	1,23	46,5	0,617
1	2011	4	209,15	269,55	1,29	95,5	0,6416
1	2011	5	108,27	112,91	1,04	63,5	0,5296
1	2011	6	180,04	227,01	1,26	85,5	0,6202
1	2011	7	285,58	367,18	1,29	129	0,5939
1	2011	8	100,08	113,44	1,13	44,5	0,5355
2	2011	1	40,88	30,82	0,75	34	0,1906
2	2011	2	41,77	29,04	0,7	28,5	0,1987
2	2011	3	28,04	19,14	0,68	22	0,1582
2	2011	4	50,46	30,58	0,61	44,5	0,1548
2	2011	5	47,46	29,53	0,62	37	0,2322
2	2011	6	50	29,96	0,6	41	0,1723
2	2011	7	86,65	51,95	0,6	68	0,1802
2	2011	8	39,69	23,7	0,6	32	0,2124
3	2011	1	48,08	23,07	0,48	48	0,2241
3	2011	2	45,46	25,27	0,56	39	0,2162
3	2011	3	39,85	24,19	0,61	34	0,2248
3	2011	4	66,38	33,69	0,51	61	0,2036
3	2011	5	48,69	23,76	0,49	41,5	0,2382
3	2011	6	60,23	24,47	0,41	55	0,2075
3	2011	7	108,65	50,65	0,47	104	0,2259
3	2011	8	47,12	23,85	0,51	42	0,2521
1	2012	1	113,85	163,05	1,43	53	0,5634
1	2012	2	102,74	120,61	1,17	66	0,4904
1	2012	3	106,67	169,34	1,59	39	0,5768
1	2012	4	177,22	233,34	1,32	90	0,5554
1	2012	5	116,04	151,67	1,31	63	0,5338
1	2012	6	171,59	224,47	1,31	94	0,5649
1	2012	7	288,7	378,51	1,31	145	0,4965
1	2012	8	118,15	148,77	1,26	62	0,5327
2	2012	1	35,48	14,49	0,41	36	0,1756
2	2012	2	46,33	21,88	0,47	45	0,2211
2	2012	3	37,11	27,43	0,74	29	0,2007
2	2012	4	55,41	19,02	0,34	55	0,1737

2	2012	5	44,7	17,39	0,39	44	0,2057
2	2012	6	56,52	16,81	0,3	57	0,1861
2	2012	7	132,59	43,27	0,33	123	0,228
2	2012	8	43,67	20,32	0,47	41	0,1969
3	2012	1	52,74	32,02	0,61	43	0,261
3	2012	2	60,44	47,35	0,78	53	0,2885
3	2012	3	41,15	32,22	0,78	31	0,2225
3	2012	4	86,44	56,77	0,66	72	0,2709
3	2012	5	56,63	43,02	0,76	42	0,2605
3	2012	6	75,67	44,94	0,59	63	0,2491
3	2012	7	160,15	117,95	0,74	130	0,2754
3	2012	8	59,96	37,07	0,62	49	0,2704

Fonte: o autor (2013)

Novamente para evitar a multicolinearidade, foi realizada uma análise de correlação entre as novas variáveis. Os resultados da análise de correlação estão no Tabela 14.

Tabela 14 – Análise de Correlação entre variáveis utilizadas para a segunda análise de aglomerados

		MEDIA	DESV_PAD	COEF_VAR	MEDIANA	PERC_VENDA
MEDIA	Correlação	1	0,956**	0,683**	0,871**	0,744**
	Sig.		0	0	0	0
DESV_PAD	Correlação	0,956**	1	0,832**	0,701**	0,837**
	Sig.	0		0	0	0
COEF_VAR	Correlação	0,683**	0,832**	1	0,315*	0,918**
	Sig.	0	0		0,029	0
MEDIANA	Correlação	0,871**	0,701**	0,315*	1	0,415**
	Sig.	0	0	0,029		0,003
PERC_VENDA	Correlação	0,744**	0,837**	0,918**	0,415**	1
	Sig.	0	0	0	0,003	

** . Correlação significativa em 0.01

* . Correlação significativa em 0.05

Fonte: o autor (2013)

Correlações maiores do que 0,8 foram encontradas. Em função disso as variáveis foram testadas simultaneamente conforme abaixo:

- MEDIA; COEF VAR.
- MEDIA; % VENDA.
- MEDIANA; COEF VAR.
- MEDIANA; % VENDA.

A análise por subgrupo considerando todas as variáveis gerou resultados significativos

estatisticamente para todas as combinações (p -valor menor que 0,1). No entanto, a mesma loja ficou em aglomerados diferente dependendo do subgrupo de produtos em análise. Esse resultado inviabilizaria objetivo dessa análise, que é aglomerar as lojas de comportamentos semelhantes. Então o teste foi realizado considerando somente um ano a cada vez. Mesmo assim, o mesmo comportamento pode ser verificado. Em função disso, foram realizados três testes à cada loja, um para cada subgrupo. Esses testes buscaram aglomerar as lojas de acordo com as diferenças de comportamento de vendas por cada loja. No entanto, nenhuma das combinações gerou resultados significativos estatisticamente. Então, a análise foi realizada por subgrupo e por ano separadamente. Os resultados com melhor significância estão na Tabela 15. A primeira coluna da tabela indica o ano e a segunda o subgrupo de produtos. A terceira coluna indica a quantidade de aglomerados indicada pela análise do dendograma. A quarta coluna indica o número de cluster que apresentou o melhor p -valor. A quinta coluna indica, para cada análise, a loja e na sexta coluna o cluster que foi alocado. A sétima coluna indica a distância do centro do cluster na análise efetuada. Os resultados indicaram diferenças de um ano para outro, e que as diferenças entre subgrupos de produtos são importantes. Isso se nota com a observação de que houve mudanças nos aglomerados entre todos os subgrupos e de um ano para outro. Não foram encontrados resultados estatisticamente significativos para os aglomerados do subgrupo de sapatilhas de tecido.

Tabela 15 – Resultados da análise de aglomerados

ANO	SUBGRUPO	DENDOG.	Nº CLUSTERS	LOJA	CLUSTER	DISTÂNCIA
2011	RASTEIRA**	4	4	1	2	0,5028
				2	2	1,5015
				3	3	1,0012
				4	1	5,0000
				5	2	2,0000
				6	1	5,0000
				7	4	0,0000
				8	3	1,0012
	SAPATILHA*	4	4	1	1	1,1250
				2	1	4,3750
				3	3	0,0000
				4	4	1,7500
				5	1	4,1250
				6	4	1,7500
				7	2	0,0000
				8	1	0,8750

	SAPATILHA DE TECIDO	3	3	1	3	2,2380
				2	3	0,3770
				3	3	5,9920
				4	1	3,0770
				5	3	2,8540
				6	1	3,0770
				7	2	0,0000
				8	3	1,2770
2012	RASTEIRA*	3	5	1	1	0,0000
				2	5	2,3340
				3	3	0,0000
				4	4	2,0000
				5	5	0,6690
				6	4	2,0000
				7	2	0,0000
				8	5	1,6670
	SAPATILHA**	3	4	1	1	5,5000
				2	1	3,5000
				3	3	0,0000
				4	4	1,0000
				5	1	2,5000
				6	4	1,0000
				7	2	0,0000
				8	1	0,5010
	SAPATILHA DE TECIDO	3	4	1	1	3,7500
				2	1	6,2500
				3	3	0,0000
				4	4	4,5000
				5	1	4,7500
				6	4	4,5000
				7	2	0,0000
				8	1	2,2500

**. Significância abaixo de 0,05

*. Significância abaixo de 0,1

Fonte: o autor (2014)

Dentre as combinações de variáveis testadas, para cada teste a combinação que obteve o melhor desempenho no teste ANOVA foi considerada como válida. Os valores de significância e as variáveis consideradas estão na Tabela 16. No sentido de captar o nível de vendas da loja, a variável MEDIANA apresentou resultados superiores do que a MÉDIA. Somente em um teste a MÉDIA se sobressaiu à MEDIANA, para Sapatilha de Tecido no ano de 2011. No entanto, o teste ANOVA realizado apresentou p -valor de 0,146 para a variável PERC_VENDA. O resultado ficou acima do alfa de teste considerado, de 0,1, não permitindo

dar credibilidade ao teste. Quanto à segunda variável analisada, houve uma maior equivalência quanto à ocorrência, sendo três para cada variável. No entanto, COEF_VAR apresentou resultados melhores, já que nos três testes que em que teve melhor desempenho teve *p*-valor que permitiu acreditar na análise de aglomerados.

Tabela 16 – Significância dos resultados da análise de aglomerados após teste ANOVA

ANO	SUBGRUPO	Nº CLUSTERS	VARIÁVEIS	SIG.
2011	RASTEIRA	4	MEDIANA	0,000
			COEF_VAR	0,036
	SAPATILHA	4	MEDIANA	0,002
			PERC_VENDA	0,092
	SAPATILHA DE TECIDO	3	MEDIA	0,000
			PERC_VENDA	0,146
2012	RASTEIRA	5	MEDIANA	0,000
			COEF_VAR	0,059
	SAPATILHA	4	MEDIANA	0,000
			COEF_VAR	0,004
	SAPATILHA DE TECIDO	4	MEDIANA	0,001
			PERC_VENDA	0,126

Fonte: o autor (2014)

Das oito lojas, três se mantiveram sempre nos mesmos aglomerados em todos os testes: as lojas 4 e 6 juntas e a loja 7 isolada. Em função disso, essas foram as lojas escolhidas para teste do modelo de previsão de demanda. Os resultados dos testes foram diferentes quando comparados os subgrupos de produtos dentro do mesmo ano. E a comparação entre os subgrupos mostra que somente o subgrupo de sapatilhas teve os mesmos resultados em termos de aglomerados, comparando-se 2011 com 2012.

5.2 PREVISÃO DE LONGO PRAZO

Após a coleta dos dados das lojas e subgrupos de produtos selecionados, os mesmos foram tabulados. Os dados coletados por loja para os subgrupos de Rasteiras, Sapatilhas e Sapatilhas de tecido estão no APÊNDICE A. O Gráfico 1, o Gráfico 2 e o Gráfico 3 representam os dados de Rasteiras, Sapatilhas e Sapatilhas de Tecido para a loja 7, respectivamente. Os gráficos para todos os subgrupos de produtos das lojas 4 e 6 podem ser verificados no APÊNDICE B.

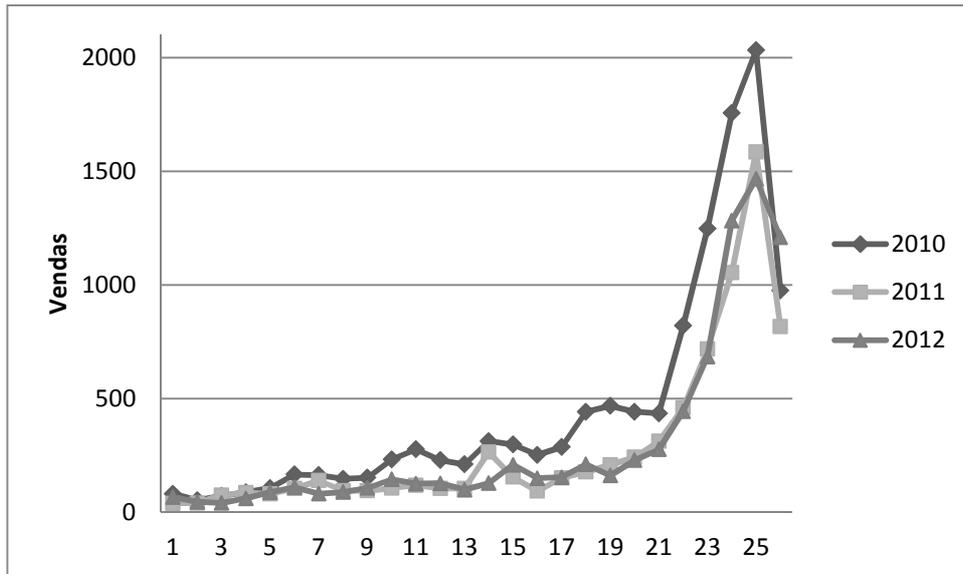


Gráfico 1 – Vendas por semana para o subgrupo de Rasteiras – Loja 7
Fonte: o autor (2014)

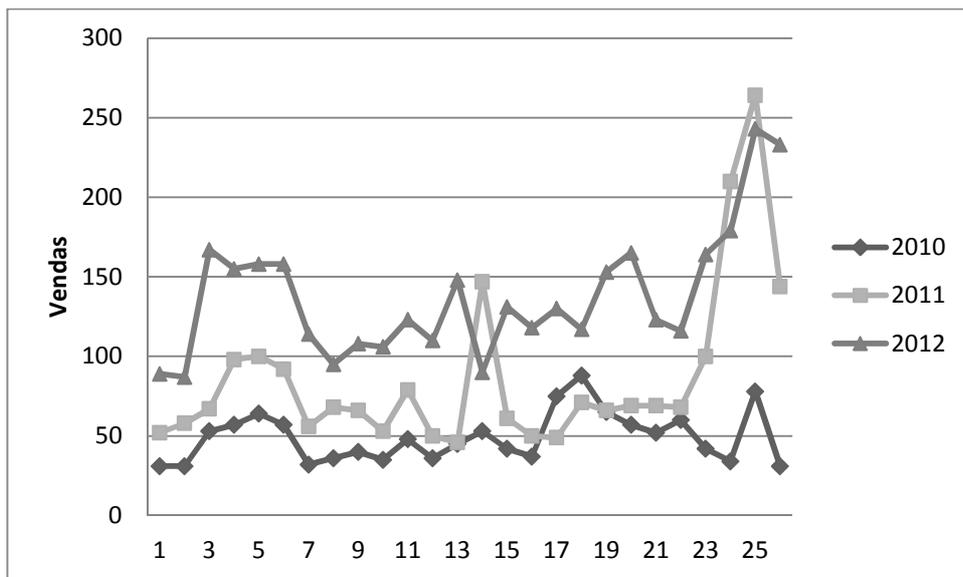


Gráfico 2 – Vendas por semana para o subgrupo de Sapatilhas – Loja 7
Fonte: o autor (2014)

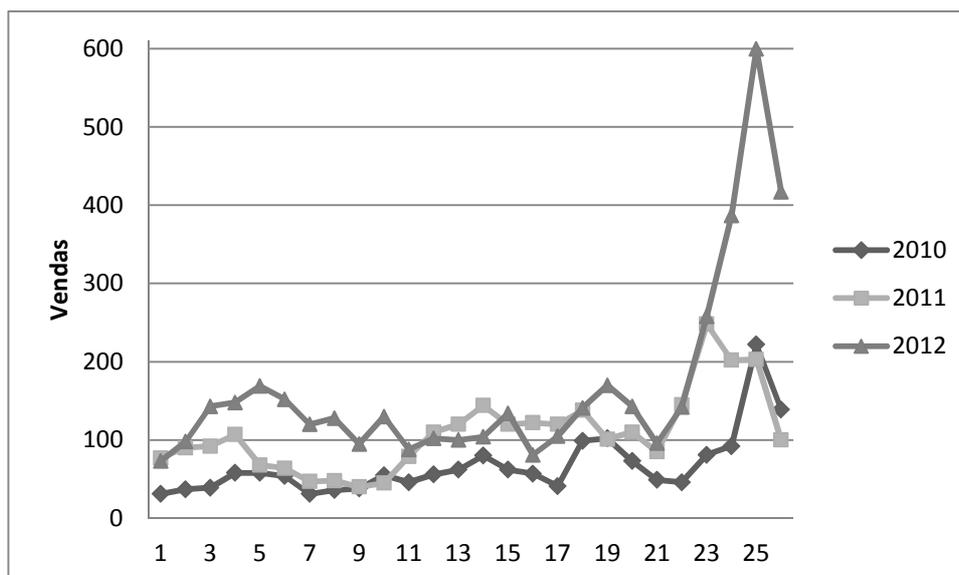


Gráfico 3 – Vendas por semana para o subgrupo de Sapatilhas de Tecido – Loja 7
Fonte: o autor (2014)

Os dados por ano, loja e subgrupo foram utilizados para realizar regressões lineares e não lineares no *software* CurveExpert. O *software* permite que diversas análises sejam realizadas de maneira conjunta. Os resultados podem ser ordenados de acordo com o desempenho nas métricas utilizadas. O CurveExpert permite que se ordene por R e R², além do desvio padrão e uma métrica identificada pelo software como *score*. Dentre os modelos sugeridos pelo *software*, escolheu-se o modelo logístico. O modelo foi escolhido em função de suas características se adequarem ao modelo proposto: crescimento exponencial inicial limitado por um elemento de saturação. Também porque demonstrou um desempenho nas métricas indicadas pelo *software* acima dos demais modelos para os três subgrupos de produtos analisados. Os parâmetros definidos pelo CurveExpert para o modelo logístico (a, b e c) foram utilizados para gerar os valores previstos pelo modelo. Os valores dos parâmetros para cada ano, subgrupo e loja estão na Tabela 17. Também estão nesse quadro os percentuais utilizados para a previsão da semana 26.

Tabela 17 – Parâmetros do modelo logístico e percentuais para semana 26

Subgrupo	Loja	Ano	a	b	c	%
Rasteiras	Loja 4	2010	-2,55E+02	-5,51E+00	6,29E-02	22,05%
		2011	-6,81E+01	-2,90E+00	4,04E-02	22,05%
		2012	-1,78E+02	-1,04E+01	8,73E-02	22,05%
	Loja 6	2010	-3,57E+02	-1,10E+01	8,65E-02	29,60%
		2011	-4,50E+01	-2,35E+00	3,25E-02	29,60%
		2012	-1,22E+02	-6,78E+00	7,17E-02	29,60%

Sapatilhas	Loja 7	2010	-4,98E+02	-9,38E+00	8,12E-02	29,17%
		2011	-1,49E+02	-4,76E+00	5,89E-02	29,17%
		2012	-3,56E+02	-1,64E+01	1,04E-01	29,17%
	Loja 4	2010	1,55E-02	-1,00E+00	4,18E-06	28,95%
		2011	3,08E+07	5,14E+05	-1,38E-02	28,95%
		2012	2,88E+07	6,28E+05	1,43E-02	28,95%
	Loja 6	2010	4,88E+01	1,01E+03	4,93E+01	38,38%
		2011	7,78E+05	1,61E+04	1,23E-03	38,38%
		2012	2,30E+07	5,27E+05	2,09E-02	38,38%
Sapatilhas de Tecido	Loja 7	2010	1,12E+02	1,82E+00	2,87E-02	29,30%
		2011	-9,50E-03	-1,00E+00	1,01E-05	29,30%
		2012	2,18E+08	2,05E+06	1,73E-02	29,30%
	Loja 4	2010	7,12E+01	5,74E-01	1,77E-01	27,41%
		2011	1,84E+03	6,81E+01	6,47E-02	27,41%
		2012	-2,23E-03	-1,00E+00	2,64E-06	27,41%
	Loja 6	2010	-1,66E-03	-1,00E+00	1,96E-06	30,49%
		2011	-1,82E+02	-6,27E+00	3,09E-02	30,49%
		2012	-8,13E-03	-1,00E+00	9,44E-06	30,49%
Loja 7	2010	-7,35E-03	-1,00E+00	8,51E-06	32,40%	
	2011	-1,32E-02	-1,00E+00	6,34E-06	32,40%	
	2012	-3,40E-02	-1,00E+00	2,65E-05	32,40%	

Fonte: o autor (2014)

Do Gráfico 4 ao Gráfico 12 são apresentados os resultados previstos e realizados para o ano de 2013. Sendo que a variável 2013* foi o valor previsto e 2013 o valor realizado. Os valores previstos para cada semana e cada previsão por ano pode ser encontrada no APÊNDICE C. No APÊNDICE D estão os gráficos das três previsões que deram origem a previsão 2013* (2010*, 2011* e 2012*).

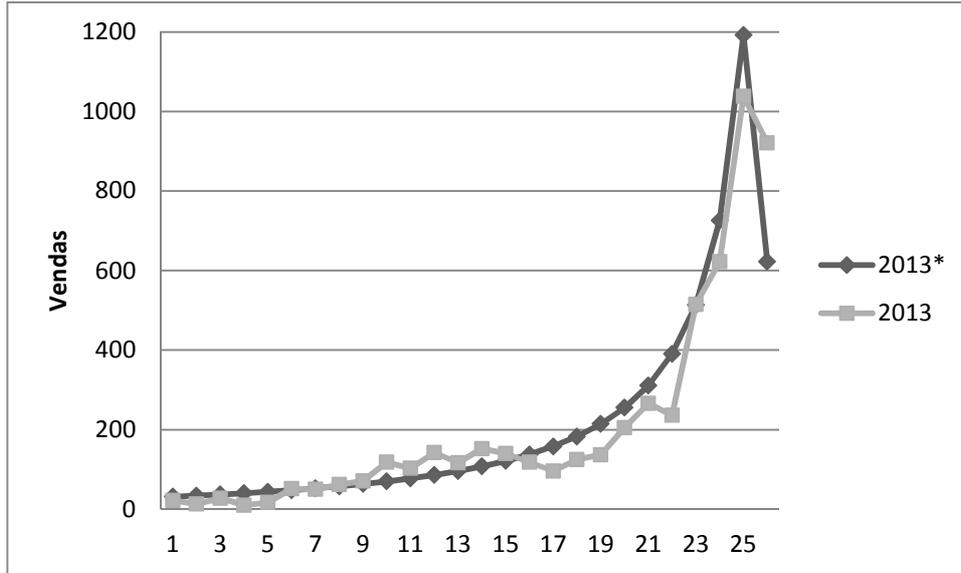


Gráfico 4 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Rasteiras – Loja 4
 Fonte: o autor (2014)

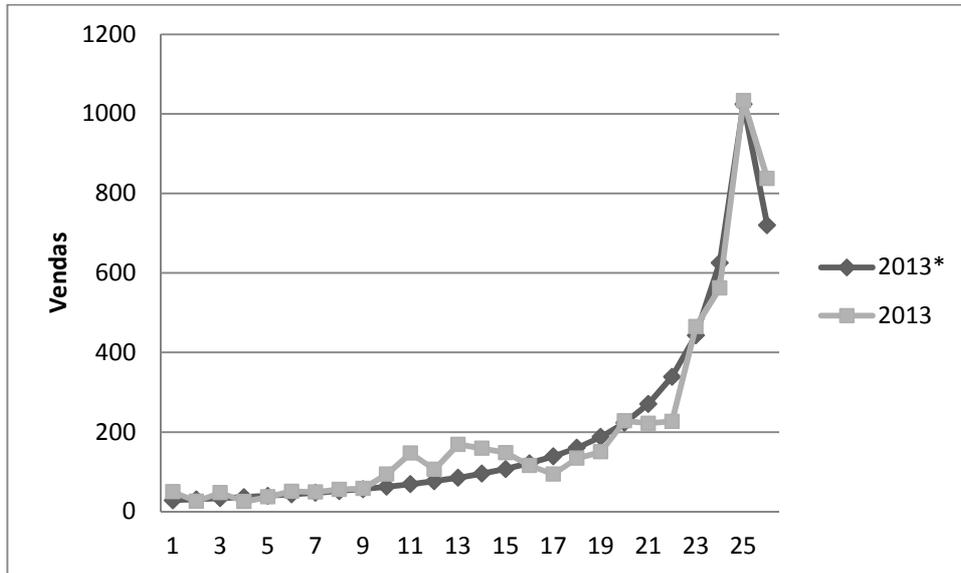


Gráfico 5 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Rasteiras – Loja 6
 Fonte: o autor (2014)

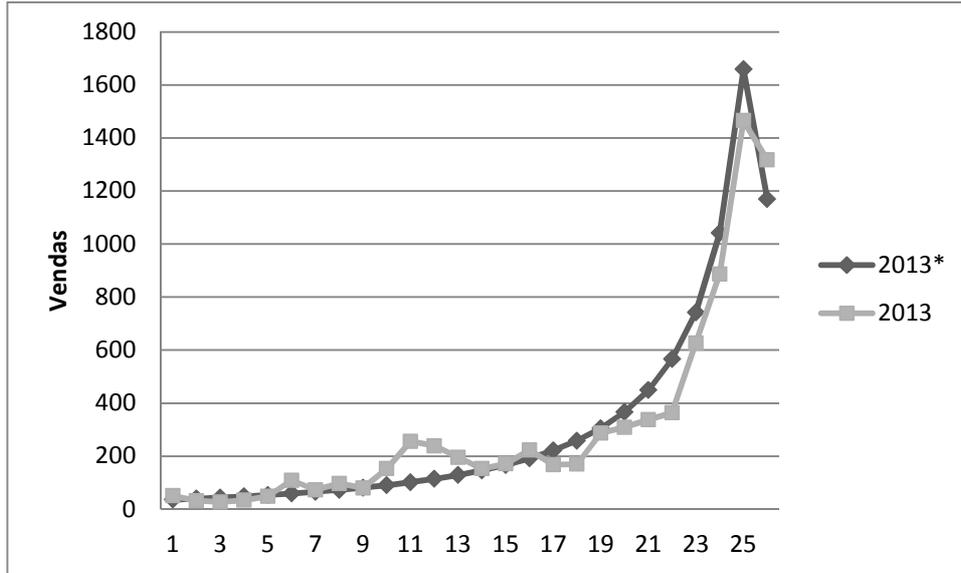


Gráfico 6 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Rasteiras – Loja 7
 Fonte: o autor (2014)

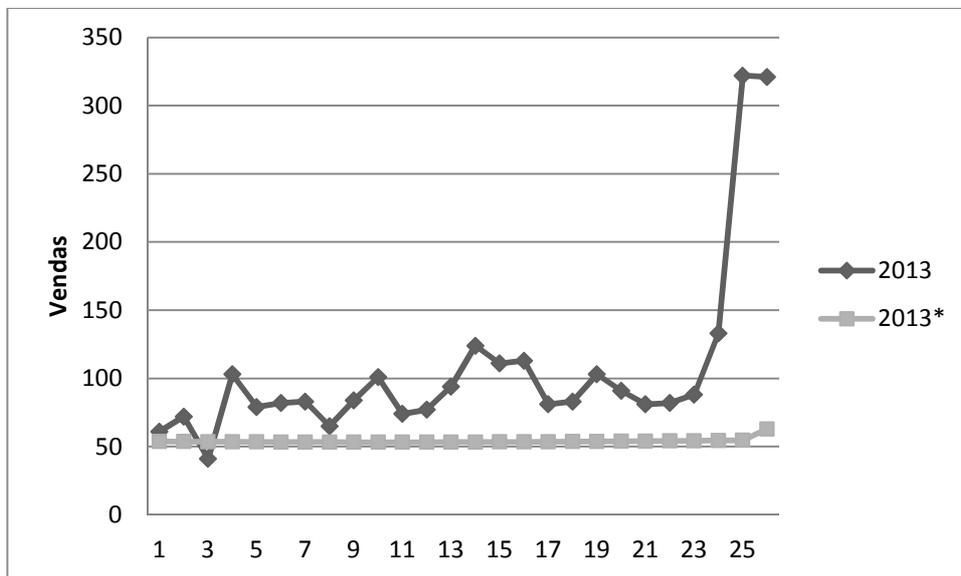


Gráfico 7 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Sapatilhas – Loja 4
 Fonte: o autor (2014)

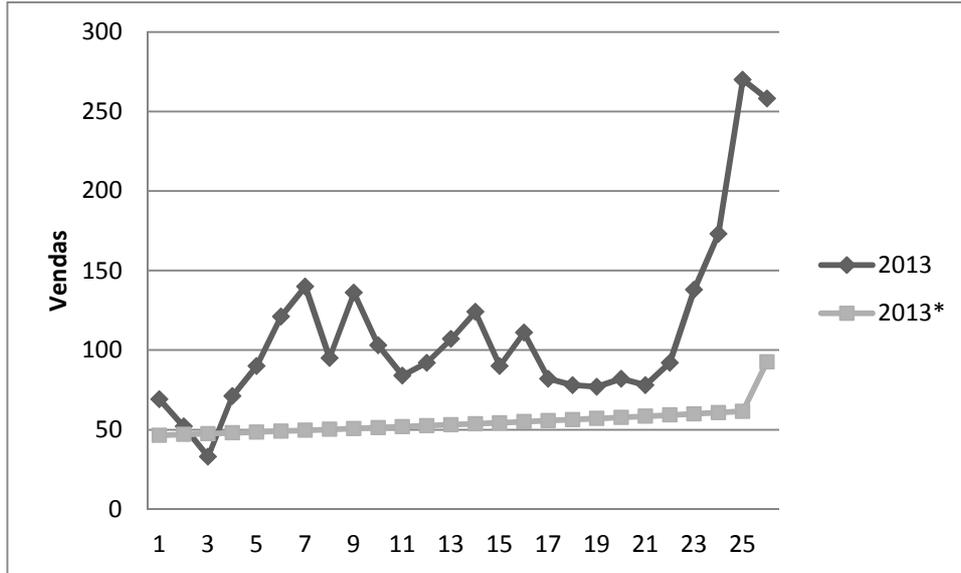


Gráfico 8 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Sapatilhas – Loja 6
 Fonte: o autor (2014)

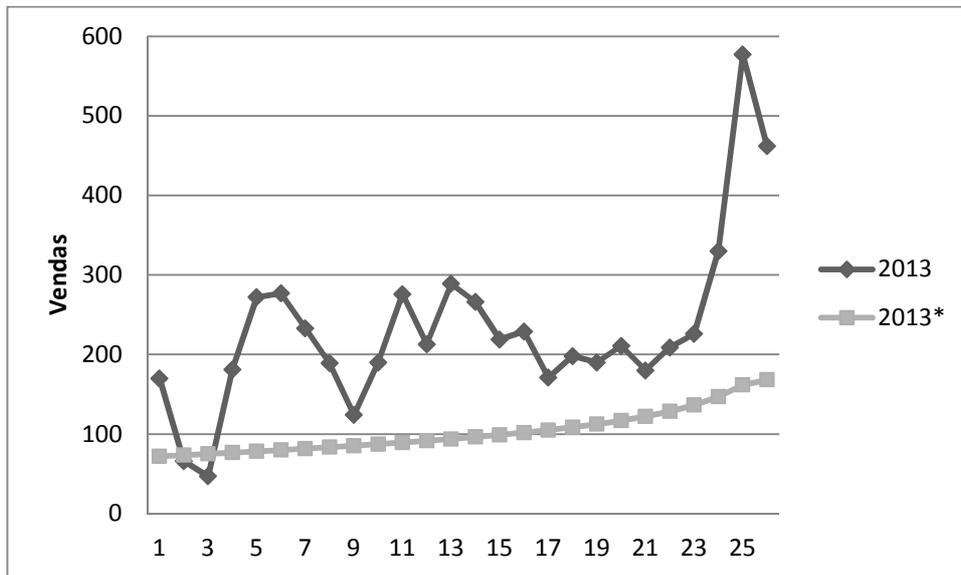


Gráfico 9 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Sapatilhas – Loja 7
 Fonte: o autor (2014)

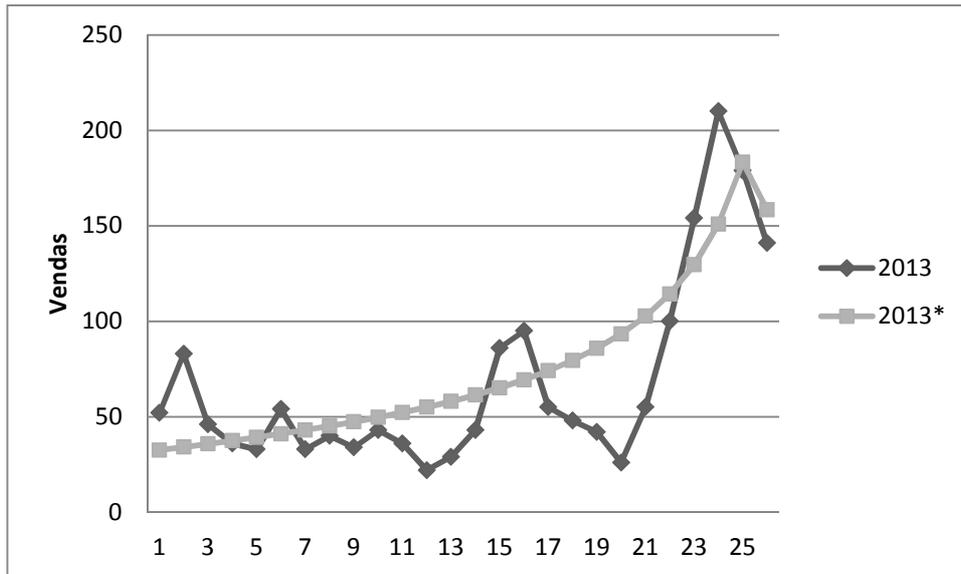


Gráfico 10 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Sapatilhas de Tecido – Loja 4
 Fonte: o autor (2014)

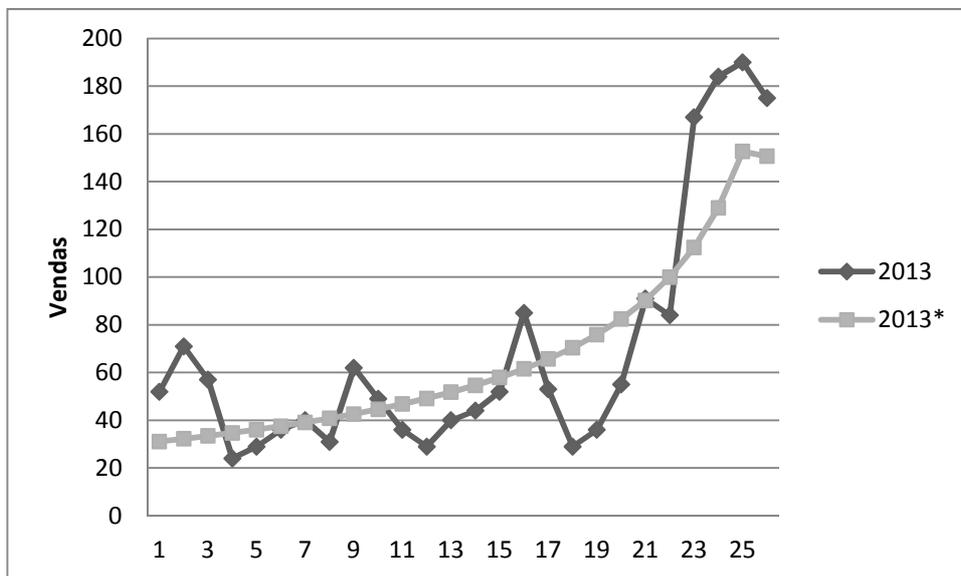


Gráfico 11 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Sapatilhas de Tecido – Loja 6
 Fonte: o autor (2014)

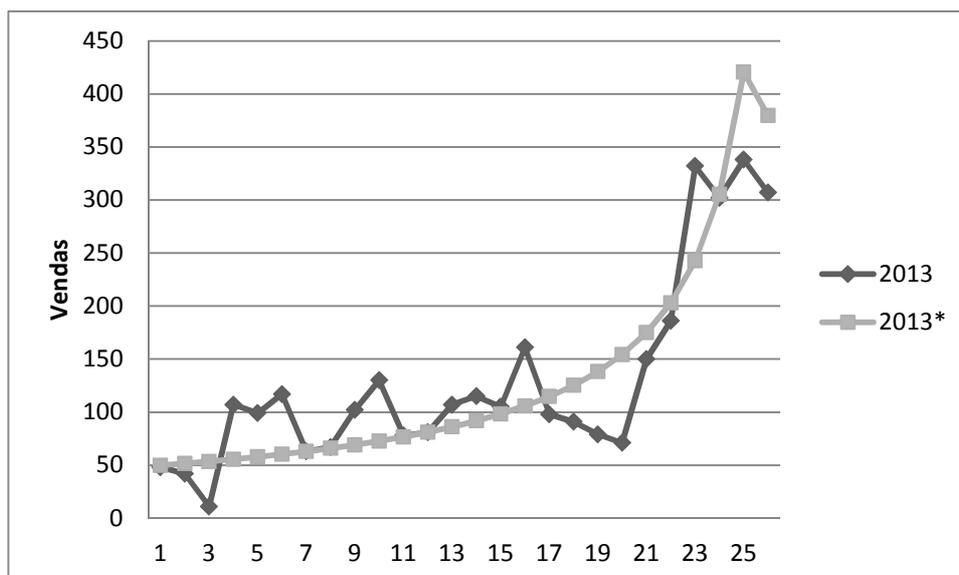


Gráfico 12 – Modelo de previsão final 2013 e Realizado 2013 para subgrupo de Sapatilhas de Tecido – Loja 7
Fonte: o autor (2014)

Após a definição da previsão de demanda para os subgrupos por loja, foram coletadas as quantidades de produtos vendidos (considerando produto e cor) por semana dos anos 2011 e 2012. Esses valores foram coletados somente para o subgrupo de rasteiras da Loja 7. O valor utilizado como média de produtos vendidos para obter a razão de incremento semanal foi a média ponderada entre os dois anos, sendo que 2012 teve o dobro de peso que 2011. Além desses valores, as quantidades de produtos vendidos de 2013 também estão na Tabela 18.

Tabela 18 – Número de modelos vendidos por semana do subgrupo de Rasteiras – Loja 7

Sem.	2011	2012	Média	2013
4	21	18	19	12
5	27	18	21	20
6	32	25	27	34
7	39	24	29	33
8	32	28	29	29
9	33	29	30	30
10	36	35	35	50
11	37	36	36	61
12	45	33	37	65
13	48	33	38	64
14	52	40	44	67
15	44	39	41	65
16	42	47	45	78

17	58	50	53	61
18	70	55	60	65
19	76	65	69	90
20	86	83	84	98
21	99	86	90	104
22	103	107	106	115
23	111	122	118	141
24	112	127	122	151
25	107	147	134	172
26	108	141	130	171

Fonte: o autor (2014)

Então, a quantidade semanal prevista pelo modelo logístico foi dividida pela média do número de modelos vendidos (considerando modelo e cor) para se obter a RIS* de 2013, ou seja, a variável prevista. Na Tabela 19 também está a RIS 2013, ou seja, a variável realizada.

Tabela 19 – Razão de incremento Semanal Prevista e Realizada para subgrupo de Rasteiras 2013 – Loja 7

Sem.	RIS* 2013	RIS 2013
4	2,55	2,83
5	2,55	2,45
6	2,17	3,21
7	2,26	2,21
8	2,49	3,34
9	2,68	2,67
10	2,57	3,06
11	2,80	4,20
12	3,09	3,68
13	3,39	3,06
14	3,32	2,28
15	4,10	2,63
16	4,22	2,86
17	4,20	2,75
18	4,31	2,62
19	4,45	3,19
20	4,37	3,15
21	4,97	3,25
22	5,35	3,17
23	6,27	4,44
24	8,54	5,87
25	12,41	8,52
26	8,99	7,70

Fonte: o autor (2014)

Os dados reais coletados foram divididos, as quantidades semanais vendidas pelo número de modelos vendidos. Essas duas variáveis que foram consideradas realmente adiante, na previsão de curto prazo. O Gráfico 28 apresenta a evolução das variáveis RIS 2013 e RIS 2013*.

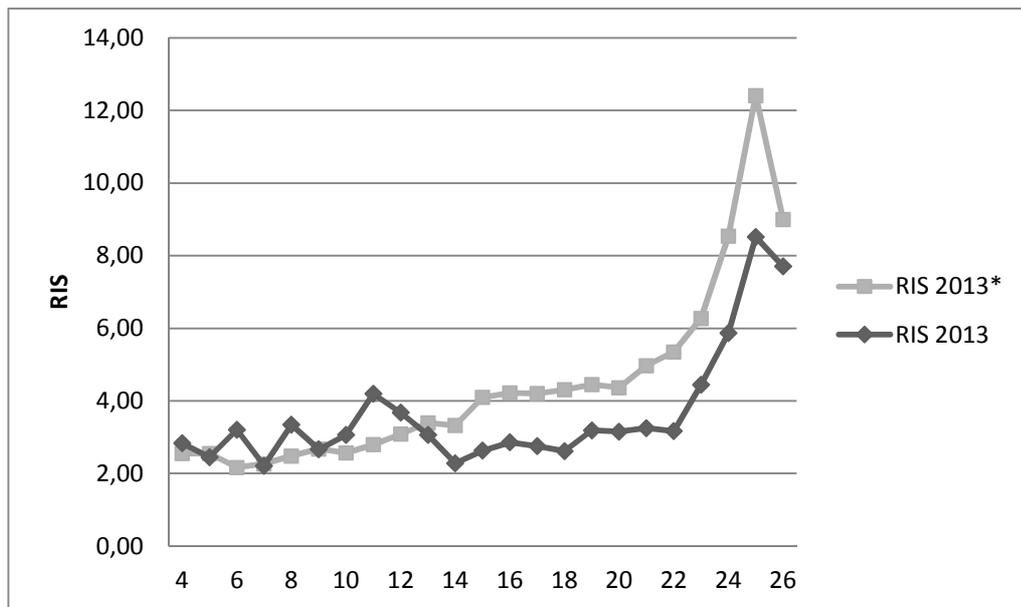


Gráfico 28 – Razão de Incremento Semanal Previsto e Realizado para subgrupo de Rasteiras 2013 – Loja 7

Fonte: o autor (2014)

5.3 PREVISÃO DE CURTO PRAZO

Para realização da decomposição da previsão para o curto prazo, foram coletados e tabulados dados com maior detalhamento do que para os passos anteriores. Foram coletados dados de venda diária por SKU dos meses de julho até dezembro de 2013. Após o término da tabulação, os valores da primeira semana de vendas foram utilizados para realização da previsão de acordo com o modelo ora proposto. Os valores previstos foram confrontados com a previsão original e com os valores reais das vendas. A Tabela 20 apresenta para a semana 5 os valores de vendas realizadas, as previsões realizadas pelo modelo ora proposto e as previsões pelo modelo original. A semana 5 foi analisada como uma amostra do início da estação, sendo que as vendas reais seguiram por mais tempo do que o representado.

Tabela 20 – Previsão de vendas para a semana 5 – Loja 7

MODELO	5	6	7	8	9	10	11	12
RT 0141 - PRETO	3	1	3	4	4	1	1	2
MODELO		3	2	3	3	3	1	1
ORIGINAL	4	4	4	4	4	4	0	0
RT 0141 - VIOLETA	3	1	1	0	0	1	2	0
MODELO		3	2	3	3	1	1	1
ORIGINAL	4	4	4	4	4	2	0	0
RT 0141 - CENOURA	2	3	1	0	1	4	3	0
MODELO		2	2	2	2	2	2	2
ORIGINAL	4	4	4	4	4	3	0	0
RT 0141 - FERRUGEM	2	3	3	3	1	1	3	2
MODELO		2	2	2	2	2	2	2
ORIGINAL	5	5	5	5	5	2	0	0
RT 0150 - CARAMELO	2	2	1	0	0	1	2	2
MODELO		2	2	2	2	2	3	2
ORIGINAL	6	6	6	6	6	5	0	0
RT 0150 - CENOURA	1	1	1	2	0	3	0	2
MODELO		1	1	1	1	1	1	1
ORIGINAL	4	4	4	4	4	4	0	0
RT 0150 - AMARELO	0	0	2	2	0	0	0	2
MODELO		0	0	0	0	0	0	0
ORIGINAL	4	4	4	4	4	4	0	0
RT 0150 - MARINHO	0	0	0	1	0	0	1	5
MODELO		1	1	1	1	1	1	1
ORIGINAL	6	6	6	6	5	3	0	0
RT 0155 - CAFÉ	1	9	5	6	1	2	6	0
MODELO		1	1	1	1	1	2	1
ORIGINAL	6	6	6	6	5	3	0	0
RT 0155 - MARINHO	1	1	1	2	0	1	10	1
MODELO		1	1	1	1	1	1	1
ORIGINAL	5	5	5	5	5	5	0	0
RT 0155 - OURO	1	13	1	3	3	7	5	1
MODELO		1	1	1	2	2	2	2
ORIGINAL	7	7	7	6	5	5	0	0

Fonte: o autor (2014)

As demais tabelas com os resultados para cada semana analisada podem ser

verificadas no APÊNDICE E. A semana 10 foi analisada como uma amostra intermediária da estação. A semana 14 foi analisada como uma amostra central da estação em termos de tempo. A semana 19 foi analisada como uma amostra da parte final da estação, bem como a semana 21, que cobriu até a última semana do ano.

6 DISCUSSÃO

Nesse capítulo serão discutidos os resultados da aplicação do modelo de previsão ora proposto. O primeiro subcapítulo abordará da análise de aglomerados realizada, o segundo subcapítulo a aplicação do modelo de longo prazo, o terceiro subcapítulo o modelo de previsão de curto prazo, e por fim serão discutidas implicações gerenciais considerando a utilização do modelo.

6.1 ANÁLISE DE AGLOMERADOS

A análise de aglomerados não permitiu que se obtivesse um resultado considerando todas as informações coletadas de maneira agrupada. Foi necessário dividir as variáveis por subgrupos de produtos e por ano. Isso implica que, para o caso em questão, a análise de aglomeração deveria ser realizada anualmente ou até por estação. Havendo diferenças na composição dos aglomerados ao mudar ano ou subgrupo de produtos, a aglomeração entre as lojas deveria ser desconsiderada. E a análise então deveria ser realizada isoladamente, não em conjunto. Isso porque se houve mudança de um ano para outro ou de um subgrupo para outro, provavelmente haverá erros em algum ponto da generalização, que é o objetivo da aglomeração, para simplificação do trabalho de análise, previsão e planejamento de estoques. A análise poderia ser realizada por subgrupo, mudando a aglomeração de lojas de acordo com o subgrupo. No entanto, essa ação pode tornar o processo de tomada de decisão mais complexo e não mais simples, que é objetivo dessa etapa.

Mesmo assim, os resultados das vendas das lojas 4 e 6 que ficaram no mesmo aglomerado foram próximas. Os valores das vendas por subgrupo para o ano de 2013 podem ser comparados nos Gráficos 29, Gráfico 30 e Gráfico 31. A análise de aglomerados foi realizada nos anos de 2011 e 2012. Estando o comportamento das vendas de 2013 próximos, pode-se dizer que o resultado da aglomeração foi satisfatório. Para verificar isso, foi utilizada a medida de desempenho preditivo MAPE para quantificar a diferença entre os valores verificados. E a análise dos resultados apresenta um valor pequeno. Os valores de MAPE encontrados estão na Tabela 21.

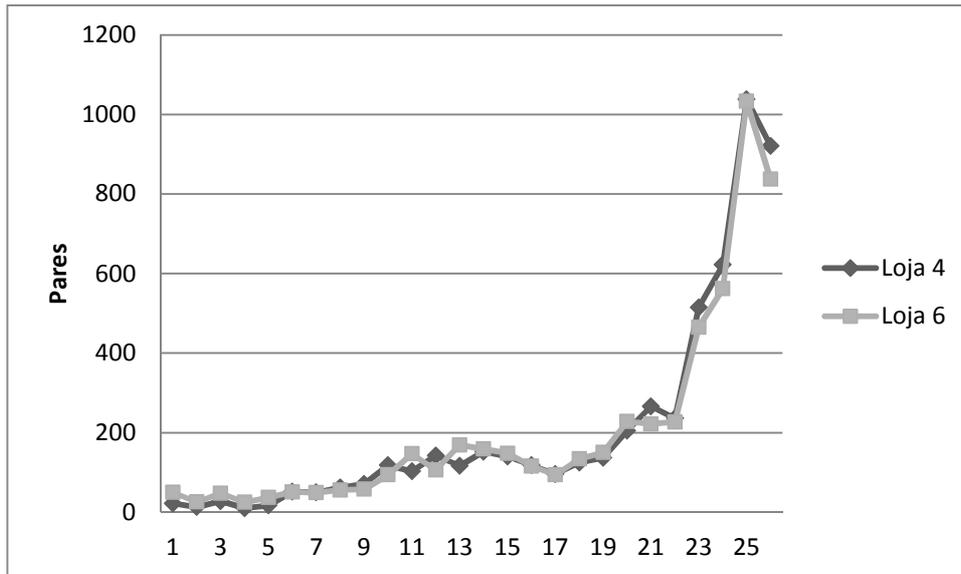


Gráfico 29 – Valores de vendas de Rasteiras realizadas em 2013 – Lojas 4 e 6
Fonte: o autor (2014)

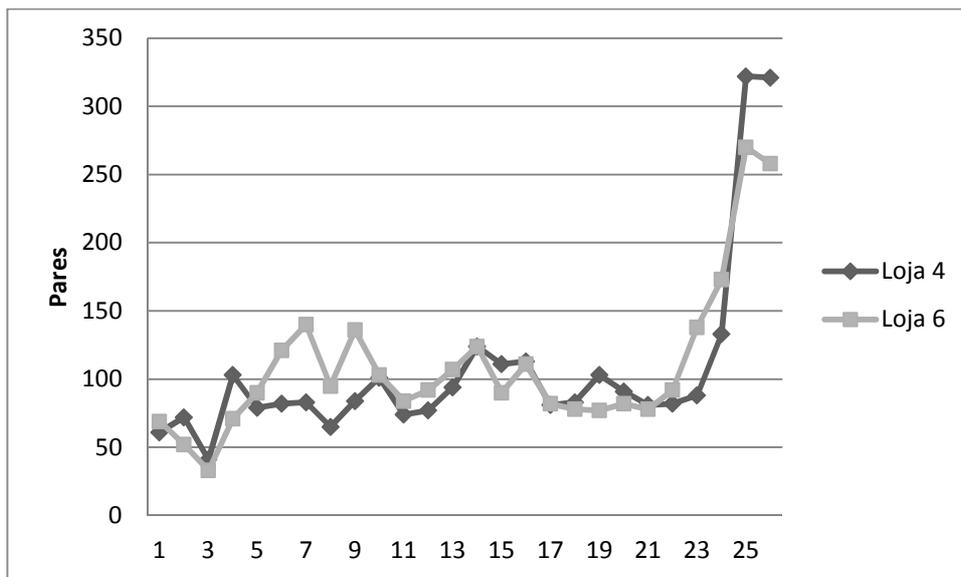


Gráfico 30 – Valores de vendas de Sapatilhas realizadas em 2013 – Lojas 4 e 6
Fonte: o autor (2014)

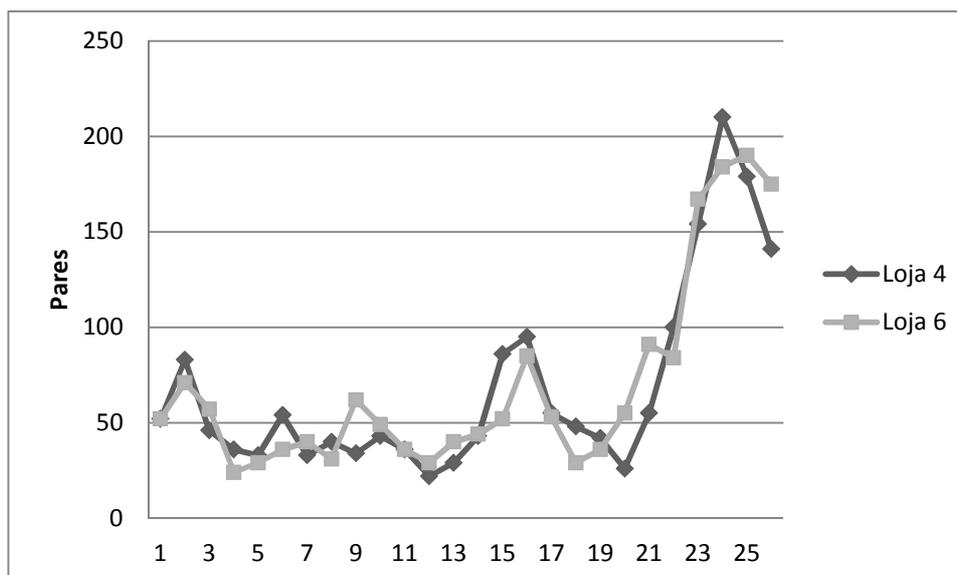


Gráfico 31 – Valores de vendas de Sapatilhas de Tecido realizadas em 2013 – Lojas 4 e 6
Fonte: o autor (2014)

Tabela 21 – Comparação entre a diferença das vendas das Lojas 4 e 6 em 2013

Subgrupo	MAPE
Rasteiras	19,766
Sapatilhas	19,689
Sapatilhas de Tecido	24,208

Fonte: o autor (2014)

Então, utilizou-se o modelo deduzido da Loja 4 para prever as vendas da Loja 6 e também do modelo da Loja 6 para prever as vendas da Loja 4, para cada subgrupo de produto. A Tabela 22 apresenta os resultados. Os valores de MSE# e MAPE# são as medidas do modelo considerado prevendo as vendas da outra loja. A comparação tanto entre MSE e MSE# como entre MAPE e MAPE# demonstram um equilíbrio entre a variação verificada. O modelo da Loja 6 prevendo as vendas de Rasteiras da Loja 4 apresenta um MSE# 46,41% menor que o original. Também o MAPE# do modelo da Loja 4 prevendo as vendas de Sapatilhas de Tecido da Loja 6 teve um valor 21,30% menor que o original. Esses resultados reforçam o que afirmam tanto Fisher e Rajaram (2000) como Mostard et al. (2011): utilizar apenas o modelo de previsão de uma das lojas para prever as vendas de ambas pode apresentar resultados satisfatórios.

Tabela 22 – Comparação entre a alternância de modelos de previsão das Lojas 4 e 6 em 2013

Subgrupo	Loja	MSE	MSE#	% VAR.	MAPE	MAPE#	% VAR.
Rasteiras	Loja 4	46,147	74,269	37,87%	23,875	26,089	8,49%
	Loja 6	81,574	55,717	-46,41%	42,645	47,322	9,88%
Sapatilhas	Loja 4	68,387	73,847	7,39%	40,455	43,159	6,27%
	Loja 6	79,902	73,763	-8,32%	38,945	36,275	-7,36%
Sapatilhas de Tecido	Loja 4	22,912	24,108	4,96%	42,283	34,858	-21,30%
	Loja 6	28,670	28,615	-0,19%	42,389	49,111	13,69%

Fonte: o autor (2014)

Foi observado na previsão de curto prazo que diversos produtos vendem rapidamente, chegando ao fim da quantidade em estoque. A análise de aglomerados não tem poder de perceber essas situações. Caso em uma loja isso ocorra e em outra não, existirá uma diferença na demanda real, que acabou perdida, e que não será obviamente percebida. Isso pode ocorrer caso a quantidade de estoque inicial seja próxima ou igual entre as duas lojas. Mesmo que haja demanda, a loja não poderá vender mais que o que tem em seu estoque. E a análise de aglomerados colocará as lojas no mesmo aglomerado, a não ser que uma loja venda muito menos que sua quantidade de estoque.

A análise de aglomerados permite que, com base na opinião de um especialista, uma loja nova poderia ser associada a um dos aglomerados existentes. Considerando que uma loja nova não possua dados históricos, a previsão de longo prazo seria impossível. Essa talvez seja a principal contribuição para a aplicação prática do modelo ora proposto. Assim, o modelo poderia ser aplicado também para lojas novas, desde que com alguma cautela e parcimônia.

6.2 PREVISÃO DE LONGO PRAZO

O modelo escolhido foi o modelo logístico. O modelo logístico é adotado largamente na previsão de crescimento de populações de organismos vivos (MIRANDA; LIMA, 2010, 2011; YANG; WILLIAMS, 2009), na previsão da difusão de novas tecnologias (QUADDUS, 1986) e na previsão do consumo de energia (BODGER; TAY, 1987). Nota-se que para a amostra de dados utilizada, as funções se ajustaram à parte inicial do “S”, antes do ponto de inflexão da curva. Isso não significa que todas as amostras alcançaram o ponto de inflexão da curva, alguns não chegaram a esse ponto. No entanto, após a série observada alcançar o valor máximo, ao invés de refletir o crescimento exponencial anterior, a série tende a diminuir ou se manter no valor alcançado. Mas apesar de apresentar uma saturação repentina, o pressuposto básico das curvas logísticas, alcançar um ponto de saturação, pode ser observado.

É provável que existam causas que gerem esse comportamento semelhante ao crescimento populacional e difusão de tecnologia para as séries analisadas. Principalmente na parte relacionada ao crescimento exponencial verificado na parte da curva antes do ponto de inflexão. Duas causas principais foram observadas: (i) o Natal, uma data especial onde existe o costume de presentear os entes próximos, gerando aumento do interesse pela compra, e (ii) os salários natalinos dos trabalhadores (décimo terceiro salário), que permitem que a intenção de compra que existe em função do Natal se realize.

Como poderá ser observado posteriormente, os modelos de previsão de sapatilhas tiveram o pior desempenho entre os subgrupos de produtos. Isso provavelmente se deve a que esse tipo de produto é mais adequado ao inverno do que ao verão. Rasteiras, por outro lado, tem uma adequação maior ao verão. Assim, com a aproximação do verão, a demanda por sapatilhas diminui, e por rasteiras aumenta. Mas os motivos para aumento da demanda no final do ano citados anteriormente tendem a equilibrar a demanda por sapatilhas. No entanto, sapatilhas de tecido tem a mesma forma que as sapatilhas. O que as diferencia é o material, que torna as sapatilhas de tecido mais baratas. E produtos de tecido se adequam às estações mais secas, como o verão. Provavelmente por isso as sapatilhas de tecido apresentem desempenho intermediário, entre sapatilhas e rasteiras.

Observando o comportamento histórico das vendas durante os anos, é possível notar pequenos picos de vendas que se repetem ao longo dos anos. O modelo logístico como adotado não é sensível a esses picos, que oscilam pouco entre as semanas 13 e 15. Para que ele fosse sensível, variáveis qualitativas ou *dummy* poderiam ser adotadas para tornar o modelo sensível. O fenômeno é menos percebido no subgrupo de Sapatilhas de Tecido. No entanto, para Sapatilhas ele apresenta um resultado importante. Esse comportamento é devido a uma promoção realizada com os produtos do início da coleção e à chegada de novos produtos à loja. Além disso, algumas oscilações para baixo podem ser causadas por falta de produtos populares em estoque, o que não pode ser descartado.

Os valores das medidas de desempenho preditivo verificados estão na Tabela 23. A medida MAPE indica a relação em percentual e permite comparar os desempenhos entre os modelos. Para Rasteiras, o modelo com pior desempenho foi o da Loja 4, com 48,20. Já para Sapatilhas, o modelo da Loja 7 obteve o pior desempenho, com 51,09. E para Sapatilhas de Tecido, o pior desempenho foi novamente do modelo da Loja 4. Comparando-se os subgrupos de produtos, o subgrupo de Sapatilhas obteve o pior desempenho, com um MAPE médio de 45,43. Já Sapatilhas de Tecido obtiveram um MAPE médio de 41,74 e Rasteiras um MAPE médio de 33,04.

Tabela 23 – Medidas de desempenho preditivo para o modelo de longo prazo

SUBGRUPO	LOJA	MSE	MAPE
Rasteiras	Loja 4	6813,59	48,20
	Loja 6	2265,71	23,35
	Loja 7	8358,64	27,57
Sapatilhas	Loja 4	6671,65	40,98
	Loja 6	5128,97	44,22
	Loja 7	22752,00	51,09
Sapatilhas de Tecido	Loja 4	837,52	49,12
	Loja 6	652,82	35,34
	Loja 7	1950,68	40,76

Fonte: o autor (2014)

No entanto, apesar de os valores de MAPE de Sapatilhas e Sapatilhas de Tecido estarem próximos, o valor de MSE para Sapatilhas é muito maior. Essa diferença se percebe quantitativamente num dado importante: o valor total de venda previsto para a estação. A Tabela 24 apresenta os valores totais previstos e realizados das vendas para a estação inteira, bem como os APE's para esse dado. Levando em consideração que a quantidade total do planejamento de vendas prevê sobras de 5% para liquidação, valores de quantidade prevista inferiores prejudicam o desempenho financeiro das lojas mais do que valores superiores. Isso concorda com Mattila et al. (2002) e Mattila (1999) que afirmam que os erros para quantidades superiores permitem melhores resultados financeiros para os varejistas.

Tabela 24 – Valores totais previstos e realizados para o modelo de longo prazo para 2013

SUBGRUPO	LOJA	TOTAL PREV.	TOTAL REAL.	APE
Rasteiras	Loja 4	5671	5376	5,49
	Loja 6	5122	5291	3,19
	Loja 7	8221	7873	4,42
Sapatilhas	Loja 4	1403	2749	48,96
	Loja 6	1428	2846	49,82
	Loja 7	2672	5995	55,43
Sapatilhas de Tecido	Loja 4	1939	1775	9,24
	Loja 6	1724	1801	4,28
	Loja 7	3398	3387	0,32

Fonte: o autor (2014)

Assim, mesmo que o MAPE da previsão do modelo de Rasteiras Loja 4 seja maior que os MAPE's do modelos de Sapatilhas das Lojas 4 e 6, o APE da venda total aponta a diferença entre a capacidade de previsão de ambos os modelos. Então, o modelo de rasteiras

se mostra apto a ser utilizado. Por outro lado, o modelo de previsão proposto não apresenta resultados satisfatórios para o subgrupo de Sapatilhas: seu uso não seria aconselhado para uma situação real.

Percebe-se que a utilização da RIS ao invés da quantidade de produtos no modelo de previsão de curto prazo representa uma redução de aproximadamente 8 a 10 vezes no incremento previsto caso fosse utilizado somente o valor da quantidade vendida. Caso não houvesse essa consideração a quantidade de produtos ofertados e vendidos no final do ano seria considerada no modelo como um incremento para cada produto, levando a um erro maior.

A RIS permite que sejam realizados testes de cenários para previsões futuras na previsão de curto prazo, aumentando a quantidade de modelos ofertados ou a profundidade das grades por modelo (o que aumentará a média de venda por modelo). O percentual aumentado ou reduzido pode ser adotado no modelo de previsão de longo prazo, criando um cenário que impactará o modelo de previsão de curto prazo.

Pode não ser interessante utilizar um método de desempenho preditivo para a RIS, já que ela pode ser uma variável de ajuste, de acordo com a quantidade de produtos comprada para cada subgrupo de produtos, ficando esse acompanhamento para o modelo de previsão em si.

6.2.1 Otimização dos coeficientes via Solver do Excel

Para verificar se os coeficientes arbitrados para determinação do modelo final foram adequados, foi realizada uma otimização dos valores dos coeficientes utilizando a ferramenta Solver do *software* Microsoft Excel. O Solver do Excel utiliza o algoritmo GRG2 para solucionar problemas lineares e não lineares (DANTAS et al., 2007; SACOMAN, 2012). O valor otimizado foi da medida de desempenho preditivo MSE do modelo, utilizando os valores realizados de 2013. Foi escolhido o MSE em função de que erros grandes são mais prejudiciais do que erros pequenos para a análise agrupada por subgrupo. Como o MSE é mais suscetível a *outliers*, que resultariam em grandes erros de previsão, essa foi a métrica escolhida para ser otimizada.

O objetivo da otimização foi minimizar o MSE. Assim, a célula destino foi a célula que continha a equação do MSE para cada ano. As células variáveis foram α_1 , α_2 e α_3 . Para proceder a otimização, as variáveis foram submetidas a restrições. E as restrições foram que cada variável fosse maior ou igual a zero, menor ou igual a um e que a soma das três variáveis

fosse igual a um. A Tabela 25 apresenta detalhadamente as variáveis e restrições da otimização. E os novos valores de coeficientes obtidos estão na Tabela 26.

Tabela 25 – Resumo das variáveis e restrições da otimização realizada

RESUMO OTIMIZAÇÃO	VARIÁVEIS
Célula Destino	MSE
Células Variáveis	a1
	a2
	a3
Restrições	a1 \geq 0
	a1 \leq 1
	a2 \geq 0
	a2 \leq 1
	a3 \geq 0
	a3 \leq 1
	a1 + a2 + a3 = 1

Fonte: o autor (2014)

Tabela 26 – Coeficientes obtidos pelo Solver para previsão de longo prazo

SUBGRUPO	LOJA	COEFICIENTE	
Rasteiras	Loja 4	α 1	0,075
		α 2	0,221
		α 3	0,705
	Loja 6	α 1	0,114
		α 2	0,886
		α 3	0,000
	Loja 7	α 1	0,000
		α 2	1,000
		α 3	0,000
Sapatilhas	Loja 4	α 1	0,000
		α 2	0,000
		α 3	1,000
	Loja 6	α 1	0,000
		α 2	0,000
		α 3	1,000
	Loja 7	α 1	0,000
		α 2	0,000
		α 3	1,000
Sapatilhas de Tecido	Loja 4	α 1	0,295
		α 2	0,000

	$\alpha 3$	0,705
Loja 6	$\alpha 1$	0,109
	$\alpha 2$	0,000
	$\alpha 3$	0,891
Loja 7	$\alpha 1$	0,008
	$\alpha 2$	0,627
	$\alpha 3$	0,364

Fonte: o autor (2014)

Os valores ótimos para o MSE oscilaram entre a priorização de $\alpha 2$ e $\alpha 3$. Talvez possa ser realizada uma adequação nos valores, reduzindo o peso do coeficiente $\alpha 1$ e aumentando o peso dos coeficientes $\alpha 2$ e $\alpha 3$. Como das nove ocorrências quatro foram zero e uma foi um valor extremamente baixo (0,008), é provável que apenas dois anos de análise sejam suficientes para se ter um modelo de previsão confiável. Com isso, o coeficiente $\alpha 1$ seria eliminado do modelo. Os novos valores de MSE e MAPE após a otimização estão na Tabela 27. Os resultados verificados permitem concluir que a lógica adotada para arbitrar os coeficientes está adequada, mas pode ser melhorada.

Tabela 27 – Medidas de desempenho preditivo para o modelo de longo prazo com coeficientes do Solver

SUBGRUPO	LOJA	MSE	MAPE	% MSE	% MAPE
Rasteiras	Loja 4	6398,33	42,65	-6,09%	-11,52%
	Loja 6	2047,63	23,88	-9,63%	2,25%
	Loja 7	6316,52	26,30	-24,43%	-4,59%
Sapatilhas	Loja 4	6138,83	38,94	-7,99%	-4,97%
	Loja 6	4496,95	40,45	-12,32%	-8,51%
	Loja 7	17840,29	43,52	-21,59%	-14,81%
Sapatilhas de Tecido	Loja 4	790,33	49,11	-5,63%	-0,02%
	Loja 6	504,77	34,86	-22,68%	-1,36%
	Loja 7	1592,95	43,16	-18,34%	5,88%

Fonte: o autor (2014)

6.3 PREVISÃO DE CURTO PRAZO

A amostra selecionada apresentou todos os comportamentos de venda esperados. Foram encontradas combinações de produtos que venderam rapidamente, terminando com o estoque antes do período previsto. Produtos que podem ser considerados populares. Para outros produtos, o tempo até o término do estoque oscilou entre seis e oito semanas. Esses

produtos se encaixariam na condição de normais. Por outro lado, também houve combinações que não venderam todas as unidades em estoque, mesmo ficando toda a estação em exposição para venda.

O modelo de previsão de curto prazo permitiu decompor a previsão de demanda agregada e atualizar a demanda por combinação de produto, apresentando resultados satisfatórios. Os valores verificados das medidas de desempenho preditivo podem ser verificadas no APÊNDICE F.

A Tabela 28 apresenta a média, a mediana e o desvio padrão para as medidas observadas. Nota-se que as observações referentes ao equilíbrio entre os desempenhos dos modelos para a APE de 8 semanas são representadas por não haver significância para afirmar que as médias são diferentes e pelos valores de mediana. A mediana é a única medida em que o modelo original apresenta desempenho superior ao modelo proposto entre todas as comparações. Além disso, os valores dos desvios-padrão demonstram que existe menos variação entre os valores do modelo proposto com relação ao original. Os erros do modelo original se concentram nos produtos que tiveram vendas menores que o esperado, para os quais o modelo proposto é mais sensível. É importante notar que somente MAPE* penaliza os modelos de previsão caso a previsão tenha sido menor do que a demanda potencial do produto. E nessa medida, o desempenho do modelo proposto foi melhor e mais estável.

Tabela 28 – Resumo das medidas de desempenho preditivo para o modelo de curto prazo

MEDIDA	PREVISÃO	MÉDIA	SIG.	MEDIANA	DESVIO PADRÃO
APE 6 SEM.	MODELO	55,199	0,008	27,619	78,913
	ORIGINAL	207,511		82,500	390,349
APE 8 SEM.	MODELO	51,232	0,129	26,225	73,917
	ORIGINAL	93,212		25,658	174,736
MAPE* 6 SEM.	MODELO	87,598	0,006	68,334	67,095
	ORIGINAL	239,777		123,333	378,627
MAPE* 8 SEM.	MODELO	88,454	0,003	73,799	63,224
	ORIGINAL	167,515		111,137	168,515

Fonte: o autor (2014)

Os Gráficos 32 e 33 apresentam uma comparação entre os desempenhos de APE para 6 semanas do modelo de previsão proposto *versus* o modelo original. Os gráficos apresentam os mesmos dados em escalas diferentes. Nota-se a predominância de pontos em que o desempenho preditivo foi melhor para o modelo ora proposto, já que os mesmos se

concentram mais próximos ao eixo dos valores do modelo original. Caso tivessem desempenho semelhante, deveriam se concentrar ao longo da diagonal entre os eixos. Os Gráficos 34 e 35 apresentam a comparação entre os desempenhos de APE para 8 semanas. Nota-se também a mesma predominância, no entanto não tão grande. Existe equilíbrio principalmente próximo ao zero. Isso acontece por uma questão lógica. Como o APE é o erro absoluto percentual e é pontual, foi realizado com a diferença da soma das vendas pela soma das previsões. A previsão original é a mais otimista possível, sempre considerando que todo o estoque foi vendido. A previsão do modelo também é forçada a ir para zero se o estoque terminar. Assim, com duas semanas a mais para vender, a chance de o estoque terminar aumenta, favorecendo os desempenhos nessa medida. No entanto, notou-se que o modelo original foi mais favorecido nessa medida nos produtos que tiveram suas vendas iniciadas nas semanas 19 e 21. As vendas da semana que antecede o Natal e da própria semana do Natal apresentam aumentos de quantidades vendidas para vários itens acima do RIS, em função da demanda de substituição. Assim, houve situações em que mesmo com vendas pequenas na semana inicial, o produto teve uma disparada de vendas nessas duas semanas. Como a previsão original é otimista, ela foi favorecida em relação ao modelo proposto.

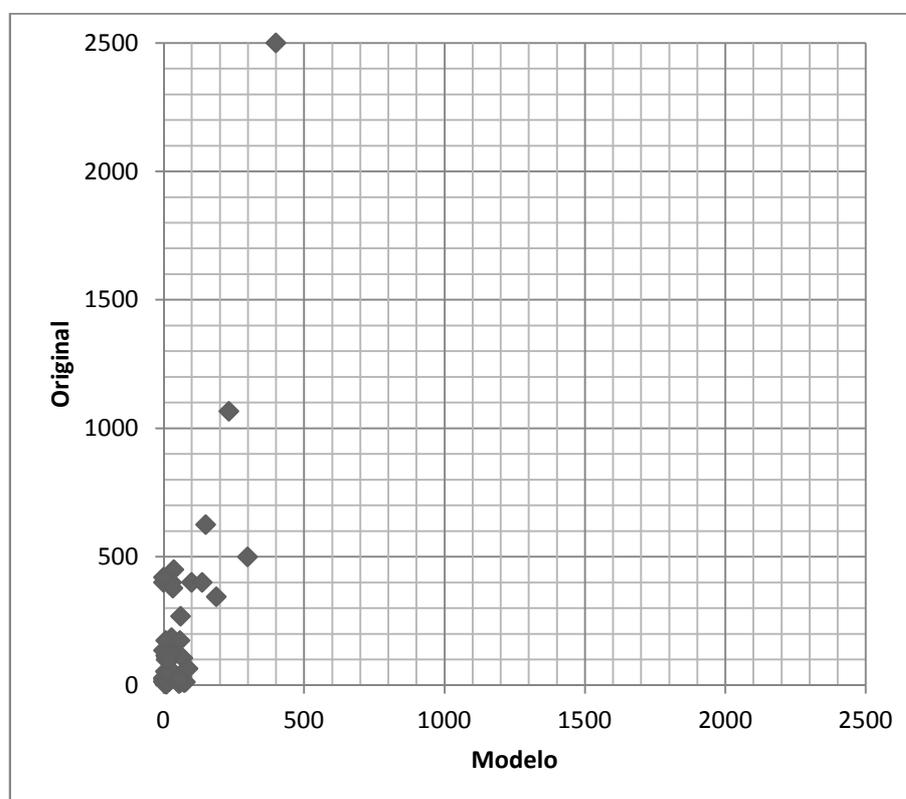


Gráfico 32 – Comparação entre os desempenhos de APE para 6 semanas I
Fonte: o autor (2014)

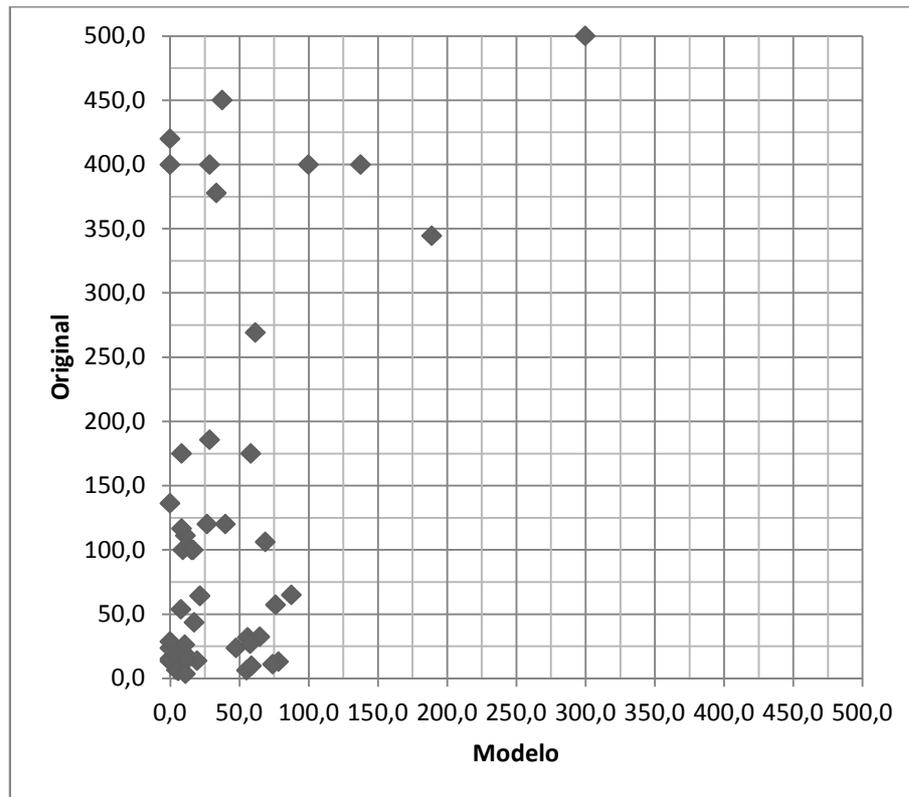


Gráfico 33 – Comparação entre os desempenhos de APE para 6 semanas II
Fonte: o autor (2014)

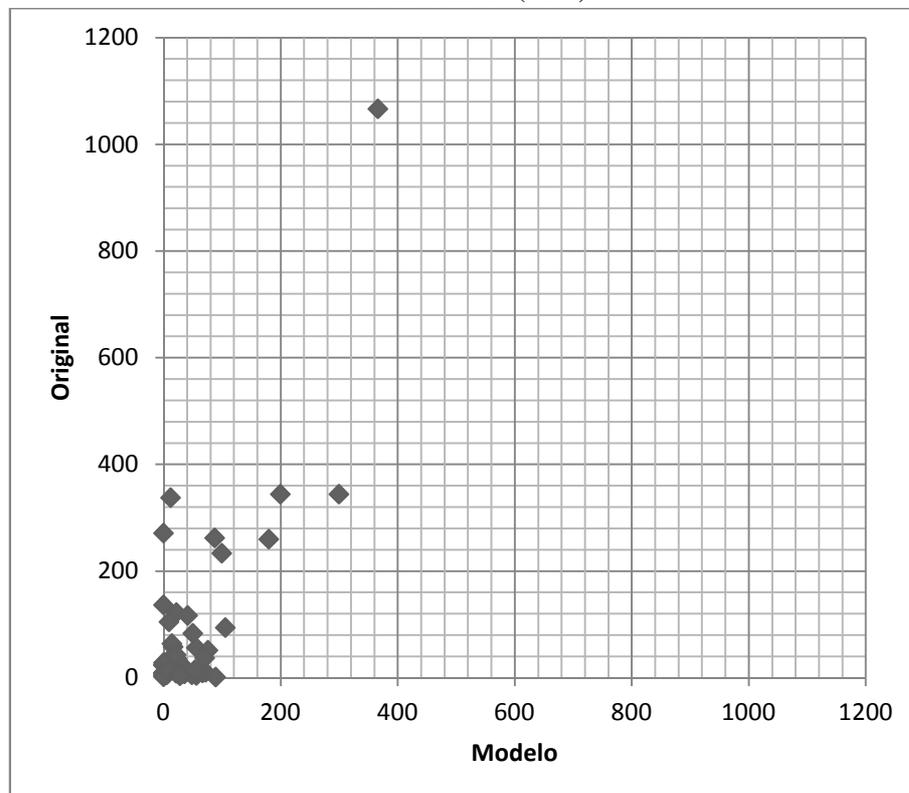


Gráfico 34 – Comparação entre os desempenhos de APE para 8 semanas I
Fonte: o autor (2014)

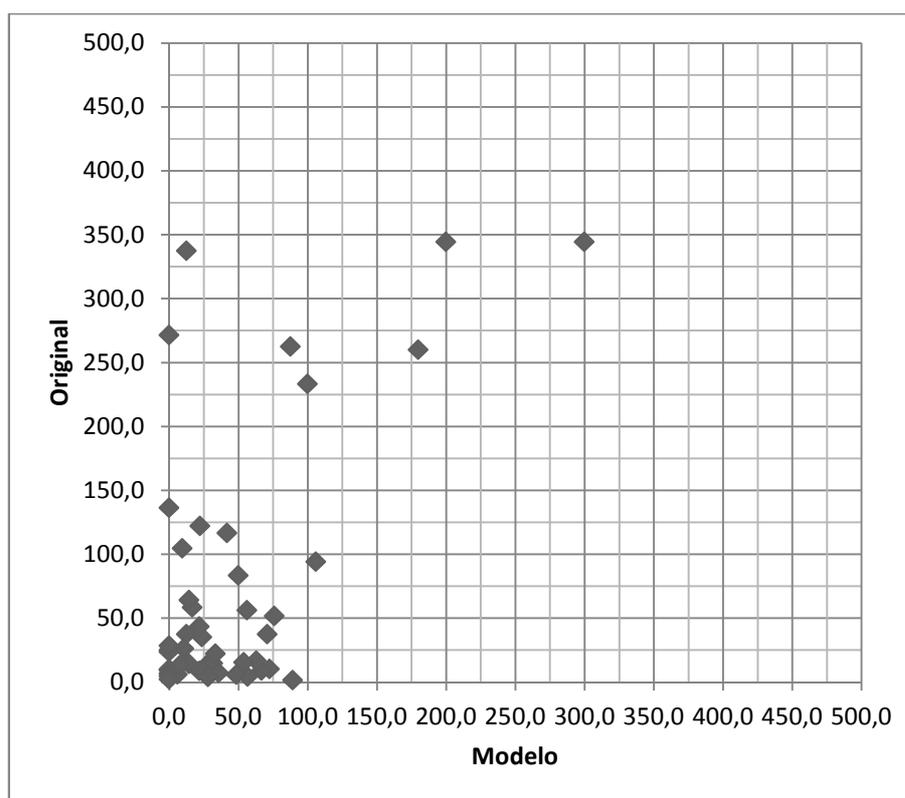


Gráfico 35 – Comparação entre os desempenhos de APE para 8 semanas II
Fonte: o autor (2014)

Os Gráficos 36 e 37 apresentam uma comparação entre os desempenhos de MAPE* para 6 semanas do modelo de previsão proposto *versus* o modelo original. Os gráficos apresentam os mesmos dados em escalas diferentes. Da mesma forma que ocorreu para o APE, nota-se a predominância de pontos em que o desempenho preditivo foi melhor para o modelo ora proposto. Os Gráficos 38 e 39 apresentam a comparação entre os desempenhos de MAPE* para 8 semanas. Diferentemente do que observou para o APE, observa-se um nível semelhante de predominância dos pontos com melhor previsão entre 6 e 8 semanas.

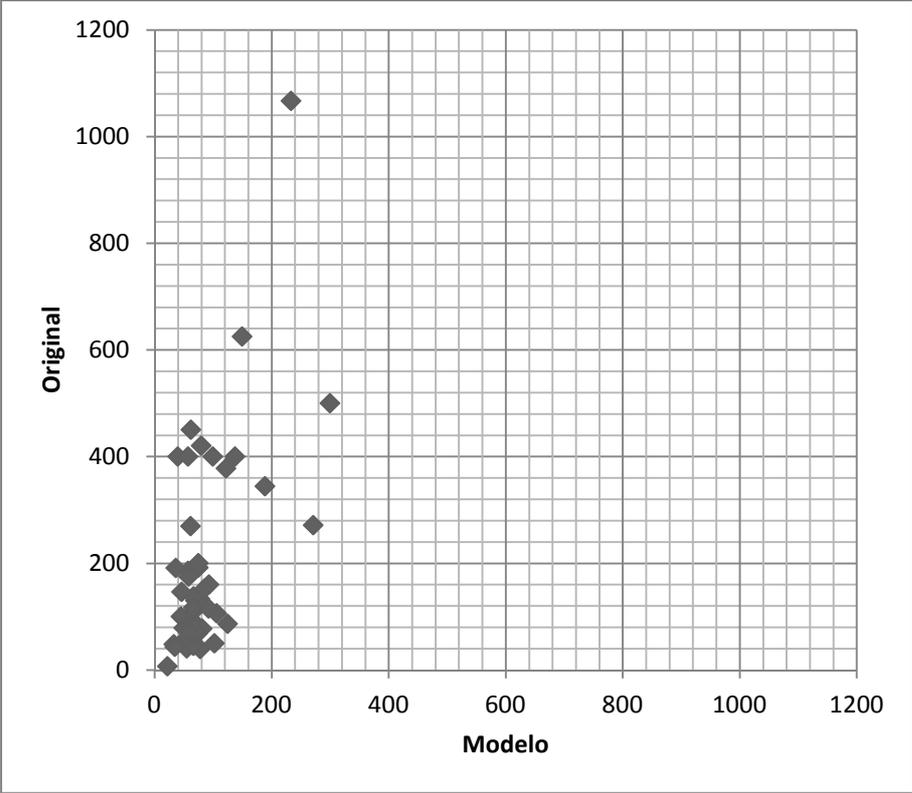


Gráfico 36 – Comparação entre os desempenhos de MAPE* para 6 semanas I
Fonte: o autor (2014)

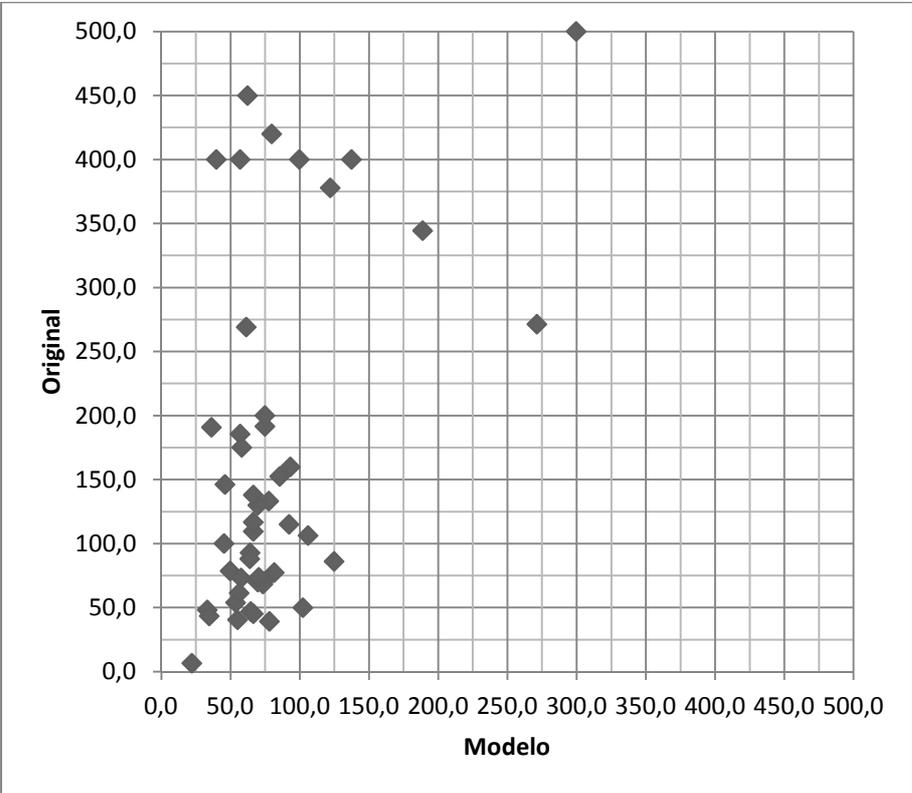


Gráfico 37 – Comparação entre os desempenhos de MAPE* para 6 semanas II
Fonte: o autor (2014)

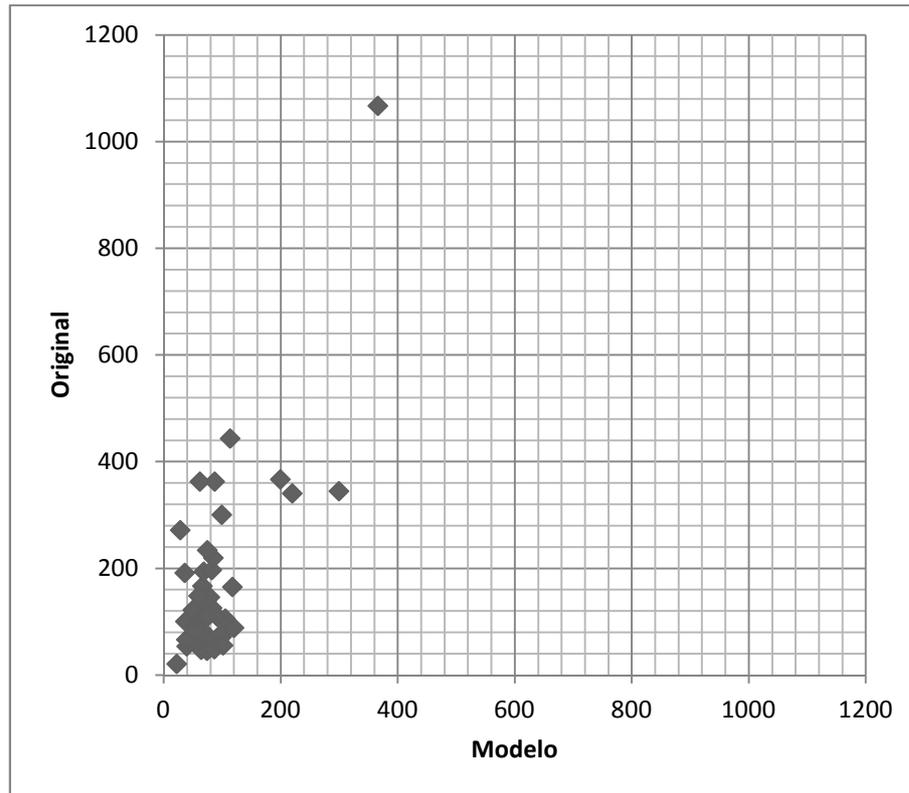


Gráfico 38 – Comparação entre os desempenhos de MAPE* para 8 semanas I
Fonte: o autor (2014)

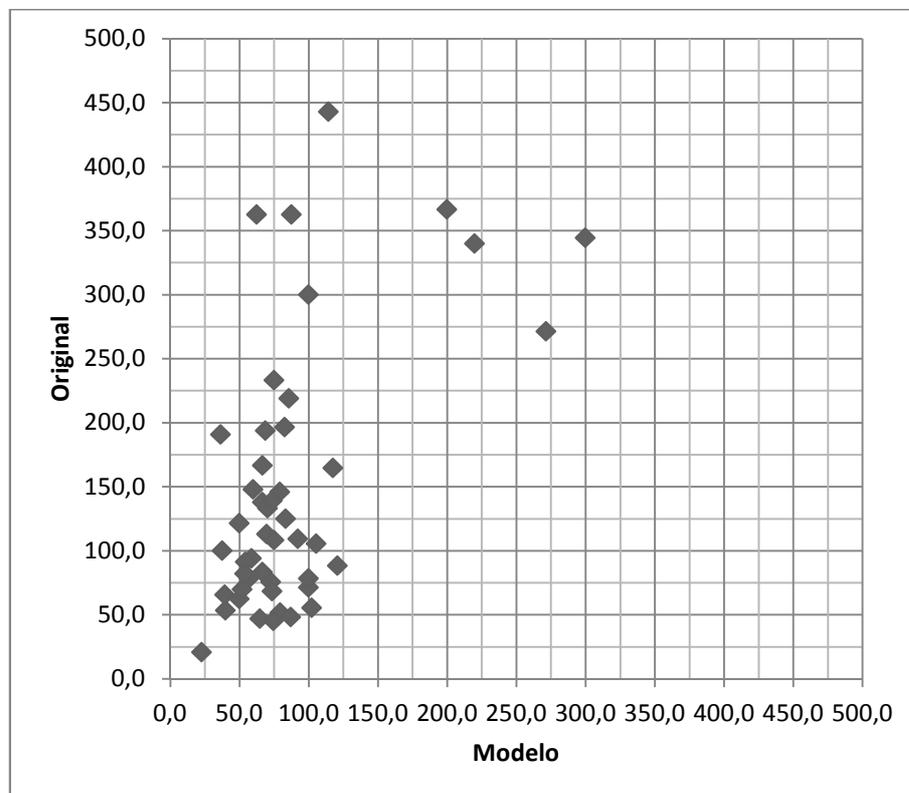


Gráfico 39 – Comparação entre os desempenhos de MAPE* para 8 semanas II
Fonte: o autor (2014)

Em todos os gráficos se destaca um produto com valores elevados, tanto de APE quanto de MAPE*. Para o produto RT 0173 se esperava um desempenho melhor, tendo em vista a quantidade comprada, acima da média. Ele vendeu um item na primeira semana, e depois vendeu somente mais 3 pares no período da análise. Esse produto é um caso a parte, como se observa. Mesmo assim, a previsão do modelo proposto foi melhor do que a original.

No entanto, alguns produtos tiveram um comportamento não conforme o esperado. A segunda semana de vendas e as demais apresentaram valores muito superiores à primeira. Uma revisão nos dados originais permitiu identificar que essa distorção foi gerada pelo método utilizado para tabulação: não houve uma semana completa de venda para análise em todos esses modelos. Esse erro foi verificado nos modelos RT 0155, RT 0158 e RT 0176, obviamente que para todas as cores. De uma maneira inesperada, esse erro reforça a ideia de que a venda da primeira semana é um bom indicativo do total de pares que o produto venderá. Isso porque as análises foram refeitas desconsiderando a primeira semana, reduzindo a quantidade vendida do estoque do produto. A Tabela 29 apresenta os valores identificados antes (APE e MAPE*) e depois da análise (APE# e MAPE*#).

Tabela 29 – Medidas de desempenho preditivo ajustadas para modelos com comportamento não conforme

SEM.	MODELO		6 SEM.	8 SEM.
5	RT 0155 - CAFÉ	APE	78,261	72,414
		APE#	20,000	14,29
		MAPE*	78,261	79,310
		MAPE*#	80,000	80,95
5	RT 0155 - MARINHO	APE	0,000	56,250
		APE#	28,571	0,00
		MAPE*	40,000	68,750
		MAPE*#	71,429	77,78
5	RT 0155 - OURO	APE	74,074	66,667
		APE#	21,053	15,00
		MAPE*	74,074	72,727
		MAPE*#	147,368	145,00
10	RT 0158 - AREIA	APE	0,000	21,739
		APE#	5,882	4,76
		MAPE*	81,818	100,000
		MAPE*#	100,000	119,05
10	RT 0158 - PRETO	APE	5,882	5,882
		APE#	10,526	10,53

		MAPE*	64,706	64,706
		MAPE*#	63,158	63,16
10	RT 0158 - ROYAL	APE	21,429	14,286
		APE#	12,500	36,36
		MAPE*	50,000	57,143
		MAPE*#	62,500	72,73
19	RT 0176 - CAFÉ	APE	55,319	27,451
		APE#	0,000	0,00
		MAPE*	55,319	74,510
		MAPE*#	17,391	17,39
19	RT 0176 - CHICLETE	APE	40,000	56,522
		APE#	51,351	15,56
		MAPE*	70,000	69,565
		MAPE*#	62,162	77,78
19	RT 0176 - PRETO	APE	58,824	31,481
		APE#	2,778	0,00
		MAPE*	66,667	87,037
		MAPE*#	108,333	108,11
19	RT 0176 - ROSA	APE	4,444	0,000
		APE#	4,762	0,00
		MAPE*	22,222	22,642
		MAPE*#	71,429	72,73
19	RT 0176 - ROYAL	APE	0,000	0,000
		APE#	4,651	0,00
		MAPE*	56,410	52,000
		MAPE*#	79,070	80,00
19	RT 0176 - VERDE	APE	64,706	62,963
		APE#	12,500	0,00
		MAPE*	70,588	66,667
		MAPE*#	152,500	146,67
19	RT 0176 - VIOLETA	APE	37,500	75,862
		APE#	12,500	3,45
		MAPE*	62,500	82,759
		MAPE*#	50,000	37,93

Fonte: o autor (2014)

A Tabela 30 apresenta a média, a mediana e o desvio padrão dos valores das medidas de desempenho preditivo anteriores e posteriores ao ajuste do modelo, considerando somente os modelos que foram ajustados. Nota-se que os valores de APE tanto para 6 semanas como para 8 semanas melhoraram, principalmente para 8 semanas. Além disso, existe significância para afirmar que existem diferenças entre as médias. No entanto, os valores de MAPE* pioraram, mas não existe significância para afirmar que as médias são diferentes. Ao aplicar o

modelo em uma situação real, esse erro poderia ser facilmente evitado e corrigido com o acompanhamento de um especialista.

Tabela 30 – Resumo das medidas de desempenho preditivo ajustadas para modelos com comportamento não conforme

SEM.	MEDIDA	APE	APE#	SIG.	%	MAPE*	MAPE*#	SIG.	%
6	Média	33,880	14,390	0,045	-135,43%	60,967	81,949	0,077	25,60%
	Mediana	37,500	12,500		-200,00%	64,706	71,429		9,41%
	Desvio Padrão	30,162	13,756		-119,27%	16,438	37,443		56,10%
8	Média	37,809	7,688	0,001	-391,81%	69,063	84,559	0,195	18,33%
	Mediana	31,481	3,448		-812,96%	69,565	77,778		10,56%
	Desvio Padrão	28,341	10,686		-165,20%	18,773	37,421		49,83%

Fonte: o autor (2014)

Para alguns produtos, o incremento de vendas que ocorre no período natalino foi maior até mesmo que a proporção prevista pela RIS para diversos produtos. Esse crescimento ocorre provavelmente em função do fenômeno da demanda de substituição. Tendo os produtos populares acabado, o consumidor passa a comprar produtos que anteriormente não eram produtos de destaque.

Para perceber a influência e o impacto dos coeficientes alfa, beta e gama, foi realizado um teste com a variação de seus valores. Para se testar alfa, beta e gama foram mantidos estáveis e os valores de alfa foram modificados para 0,5 e 0,1. As médias, medianas e desvios padrão dos resultados verificados após o teste estão na Tabela 31. O coeficiente alfa define o quanto do modelo de previsão original terá de influência no modelo proposto. Empiricamente, o valor de 0,9 foi definido, de maneira que quando as vendas da primeira semana fossem zero, ainda assim houvesse algum tipo de previsão.

Tabela 31 – Análise do coeficiente alfa

MÉTRICA	MEDIDA	0,9	0,5	0,1	Sig
APE 6 SEM.	MÉDIA	55,20	110,06	180,46	0,047
	DESV. PAD.	78,91	219,03	368,62	
	MEDIANA	27,62	35,57	50,00	
APE 8 SEM.	MÉDIA	51,23	71,64	101,29	0,271
	DESV. PAD.	73,92	143,17	208,00	
	MEDIANA	26,23	18,49	23,54	
MAPE* 6 SEM.	MÉDIA	92,46	137,82	207,84	0,060
	DESV. PAD.	71,39	209,07	358,36	

	MEDIANA	70,00	79,58	87,86	
MAPE* 8 SEM.	MÉDIA	93,51	115,86	145,80	0,192
	DESV. PAD.	74,21	81,78	82,93	
	MEDIANA	67,88	130,45	194,36	

Fonte: o autor (2014)

Nota-se que assim como verificado na comparação entre o modelo proposto e o modelo original, a mediana da métrica APE para 8 Semanas com coeficiente em 0,5 foi a única que performou melhor que o coeficiente definido de 0,9. Esse resultado demonstra coerência entre os valores verificados. No entanto, somente é possível afirmar com confiança estatística de existe diferença entre as médias para a métrica APE de 6 Semanas, que apresentou um p-valor inferior a 0,05. Os valores do teste *post hoc* Tukey realizados estão na Tabela 32. Os testes foram realizados para verificar quais dos pares diferem ou não.

Tabela 32 – Testes Post Hoc da análise do coeficiente alfa

MÉTRICA	ALFA	0,9	0,5	0,1
APE 6 SEM.	0,9		0,522	0,037
	0,5	0,522		0,344
	0,1	0,037	0,344	
APE 8 SEM.	0,9		0,788	0,243
	0,5	0,788		0,606
	0,1	0,243	0,606	
MAPE* 6 SEM.	0,9		0,620	0,049
	0,5	0,620		0,323
	0,1	0,049	0,323	
MAPE* 8 SEM.	0,9		0,717	0,167
	0,5	0,717		0,551
	0,1	0,167	0,551	

Fonte: o autor (2014)

Somente se pode afirmar que existem diferenças entre as médias de 0,9 e 0,1 de APE para 6 Semanas e MAPE* para 6 Semanas. Assim, foram também testados os valores de 0,8 e 0,7 para verificar se existem variações nos valores frente ao valor de 0,9 utilizado. Assim como não foram encontradas diferenças significativas entre as médias entre coeficientes alfa 0,9 e 0,5, não se encontrou diferença com alfa em 0,9. Os valores são apresentados na Tabela 33.

Tabela 33 – Análise focada do coeficiente alfa

MÉTRICA	MEDIDA	0,9	0,8	0,7	Sig.
APE 6 SEM.	MÉDIA	55,20	58,04	75,63	0,603
	DESV. PAD.	78,91	92,52	146,27	
	MEDIANA	27,62	22,25	34,67	
APE 8 SEM.	MÉDIA	51,23	52,57	55,32	0,977
	DESV. PAD.	73,92	101,16	106,67	
	MEDIANA	26,23	22,87	18,19	
MAPE* 6 SEM.	MÉDIA	92,46	94,00	111,18	0,586
	DESV. PAD.	71,39	80,55	136,29	
	MEDIANA	70,00	65,94	71,13	
MAPE* 8 SEM.	MÉDIA	93,51	94,51	100,56	0,910
	DESV. PAD.	74,21	90,96	96,45	
	MEDIANA	67,88	73,71	78,02	

Fonte: o autor (2014)

O único valor em que o valor de 0,7 teve melhor desempenho foi a mediana para a métrica APE para 8 Semanas, assim como foi verificado anteriormente para alfa em 0,5. No entanto, o desempenho foi muito próximo nas demais métricas entre 0,9 e 0,8. Em todas as métricas a média de 0,9 foi melhor que 0,8, mas demonstrando pequena diferença. Diferença essa que mesmo entre 0,9 e 0,7 não pode ser considerada estatisticamente. E a mediana de 0,8 somente teve desempenho inferior para o MAPE* para 8 Semanas. Para verificar se essa diferença pode ser utilizada, assumindo um valor para cada período de análise (semana), foram comparados os valores das medidas filtradas por semana de análise. Os valores estão nas Tabelas 34 e 35.

Tabela 34 – Análise por semana do coeficiente alfa – Semanas 5 e 10

MÉTRICA	MEDIDA	SEM. 5			SEM. 10		
		0,9	0,8	Sig.	0,9	0,8	Sig.
APE 6 SEM.	MÉDIA	105,35	110,85	0,924	11,54	10,98	0,911
	DESV. PAD.	131,57	135,61		8,53	8,49	
	MEDIANA	74,07	56,52	0,809	10,26	7,76	0,870
APE 8 SEM.	MÉDIA	55,84	47,32	0,729	15,04	18,09	0,667
	DESV. PAD.	54,35	59,05		6,67	15,46	
	MEDIANA	56,25	25,00	0,571	14,29	14,29	0,903
MAPE* 6 SEM.	MÉDIA	125,14	137,82	0,804	67,42	61,83	0,368

	DESV. PAD.	117,36	118,57		10,71	9,79	
	MEDIANA	77,78	77,78	0,784	67,35	63,03	0,374
MAPE* 8 SEM.	MÉDIA	89,10	94,76	0,792	75,73	74,96	0,942
	DESV. PAD.	48,37	51,07		19,67	15,43	
	MEDIANA	79,31	75,00	0,784	69,20	76,47	0,840

Fonte: o autor (2014)

Tabela 35 – Análise por semana do coeficiente alfa – Semanas 14 e 19

MÉTRICA	MEDIDA	SEM. 14			SEM. 19		
		0,9	0,8	Sig.	0,9	0,8	Sig.
APE 6 SEM.	MÉDIA	147,07	194,99	0,608	32,05	29,22	0,709
	DESV. PAD.	88,17	153,64		27,37	28,15	
	MEDIANA	163,19	175,69	0,857	26,67	19,44	0,645
APE 8 SEM.	MÉDIA	219,79	289,24	0,648	32,43	27,31	0,510
	DESV. PAD.	154,24	244,09		30,62	25,91	
	MEDIANA	250,00	272,22	0,771	28,00	24,00	0,592
MAPE* 6 SEM.	MÉDIA	154,22	202,13	0,577	77,65	69,77	0,460
	DESV. PAD.	75,64	143,67		46,39	29,49	
	MEDIANA	163,19	175,69	0,857	66,67	64,71	0,741
MAPE* 8 SEM.	MÉDIA	232,29	301,74	0,615	78,71	68,05	0,288
	DESV. PAD.	132,30	225,79		45,41	24,58	
	MEDIANA	250,00	272,22	0,771	73,91	70,37	0,568

Fonte: o autor (2014)

As médias foram comparadas pelo teste ANOVA e as medianas foram comparadas pelo teste U de Mann-Whitney. Tanto as médias como as medianas não apresentaram resultados de p-valor que suportem a hipótese de que existe diferença entre as amostras. Em função disso, não se pode afirmar qual dos dois valores para o coeficiente alfa deve ser utilizado. Considerando que a média é mais afetada por valores maiores que a mediana, talvez essa seja a medida a ser adotada para se definir o coeficiente alfa. Isso porque assim, erros maiores serão mais penalizados na tomada de decisão.

Já para o coeficiente beta, foram selecionados somente os produtos que foram afetados pelo coeficiente. Esse coeficiente define o percentual de redução de demanda quando o fenômeno da quebra de grade atua sobre a mesma. O valor adotado de maneira intuitiva para esse coeficiente foi 0,3. Para se verificar a influencia, foram testados os valores de 0,1; 0,5 e 1. O valor 1 representa uma situação em que o coeficiente não está sendo aplicado, ou seja, a quebra de grade não está atuando. O valor 0,1 representa uma situação em que a quebra de grade reduz a previsão para 10% do original. Os demais coeficientes foram mantidos em seus

valores originais. Os resultados estão na Tabela 36.

Tabela 36 – Análise do coeficiente beta

MÉTRICA	MEDIDA	0,1	0,3	0,5	1,0	Sig.
APE 6 SEM.	MÉDIA	28,826	29,002	29,454	32,228	0,999
	DESV. PAD.	59,037	66,346	73,880	80,785	
	MEDIANA	11,806	10,819	9,109	11,111	
APE 8 SEM.	MÉDIA	24,17	22,53	26,98	31,32	0,960
	DESV. PAD.	44,42	44,65	56,35	68,27	
	MEDIANA	9,83	6,89	7,52	9,21	
MAPE* 6 SEM.	MÉDIA	77,24	88,30	77,27	80,24	0,952
	DESV. PAD.	65,90	72,30	66,07	72,97	
	MEDIANA	64,50	68,33	64,50	65,69	
MAPE* 8 SEM.	MÉDIA	80,92	89,13	78,47	82,28	0,944
	DESV. PAD.	59,59	61,20	48,55	59,55	
	MEDIANA	64,50	70,18	65,69	72,62	

Fonte: o autor (2014)

O p -valor do teste ANOVA demonstra que não existe diferença significativa entre as médias. Esse resultado seria esperado para a métrica APE, já que pequenas modificações na demanda semanal como as geradas pela quebra de grade não deveriam afetar tanto essa métrica. Como a métrica APE analisa os totais, se o estoque terminar uma semana antes ou depois, isso não será percebido pela métrica. No entanto, mesmo para a MAPE* não houve diferença estatística. Aparentemente, o valor de 0,5 apresenta os melhores valores para MAPE*.

Por fim, o coeficiente gama foi analisado somente entre os produtos em que se percebeu a demanda de substituição. O fenômeno ocorreu somente com produtos das semanas 10 e 19. O valor de 0,2 foi adotado em função de que somente um terço das possibilidades da ocorrência do fenômeno seriam incluídas no modelo: a substituição entre cores no mesmo modelo. Para verificar sua influencia foram testados adicionalmente os valores de 0; 0,4 e 0,6. Os coeficientes alfa e beta foram mantidos em seus valores originais. Os resultados são apresentados na Tabela 37.

Tabela 37 – Análise do coeficiente gama

MÉTRICA	MEDIDA	0,0	0,2	0,4	0,6	Sig.
APE 6 SEM.	MÉDIA	39,062	39,459	38,977	39,930	0,999
	DESV. PAD.	25,596	25,243	26,615	25,835	
	MEDIANA	38,750	38,750	41,429	41,429	
APE 8 SEM.	MÉDIA	41,72	41,43	39,52	38,37	0,984
	DESV. PAD.	28,14	29,87	31,95	28,79	
	MEDIANA	34,26	32,41	34,81	32,96	
MAPE* 6 SEM.	MÉDIA	69,89	70,29	68,13	70,61	0,983
	DESV. PAD.	20,82	20,63	18,71	19,38	
	MEDIANA	68,33	68,33	66,67	68,33	
MAPE* 8 SEM.	MÉDIA	74,37	74,57	74,54	73,44	0,997
	DESV. PAD.	17,43	19,37	18,84	17,73	
	MEDIANA	74,46	74,76	77,82	79,17	

Fonte: o autor (2014)

Como se pode notar, o *p*-valor verificado no teste ANOVA não suporta a hipótese de que existem diferenças entre as médias para nenhuma das métricas. Isso se deve em parte à limitação do estoque. Quando o produto em outra cor termina, o produto que seria destino da demanda de substituição também está terminando. Exemplo disso é o produto RT 0181 e todas as suas cores. Adicionalmente, existem cores para as quais o fenômeno da demanda de substituição foi maior do que o modelo pode prever. Exemplos são os modelos RT 0194 Cenoura, RT 0194 Ferrugem e RT 0194 Ouro. Nota-se que o pico do fenômeno ocorreu no período Natalino. Por outro lado, existem cores para as quais o modelo ajustou-se de maneira correta. Exemplos são os modelos RT 0194 Amarelo, RT 0194 Preto e RT 0194 Rose Gold.

Em função de que algumas cores apresentaram o fenômeno da demanda de substituição em intensidade maior do que o modelo pode prever, foram realizados testes com valores para o coeficiente gama aumentados, representando uma ocorrência ainda maior de demanda de substituição no modelo. Mesmo assim, os valores de *p*-valor para o teste ANOVA não foram significativos, indicando que as diferenças entre as médias não podem ser consideradas. Os resultados estão na Tabela 38.

Mesmo assim, nota-se uma redução importante na métrica APE para 8 Semanas. Essa métrica captou as variações que ocorreram graças a esse fenômeno até a última semana do ano, passando todo o período do Natal. Essa observação leva a sugestão de que se utilizem valores diferentes de gama de acordo com o período do ano: poder-se-ia utilizar um valor maior quando a previsão do modelo fosse próxima ao período Natalino. Como visto, poder-

se-ia tranquilamente passar esse coeficiente para 1,0; considerando que toda a demanda perdida fosse substituída nesse período.

Tabela 38 – Análise do coeficiente gama aumentado

MÉTRICA	MEDIDA	0,0	1,1	2,5	Sig.
APE 6 SEM.	MÉDIA	39,062	42,097	45,935	0,852
	DESV. PAD.	25,596	25,384	29,489	
	MEDIANA	38,750	41,429	42,000	
APE 8 SEM.	MÉDIA	41,72	35,45	32,83	0,779
	DESV. PAD.	28,14	34,47	34,13	
	MEDIANA	34,26	21,76	21,61	
MAPE* 6 SEM.	MÉDIA	69,89	69,36	72,44	0,955
	DESV. PAD.	20,82	18,36	21,90	
	MEDIANA	68,33	68,33	68,33	
MAPE* 8 SEM.	MÉDIA	74,37	74,22	79,94	0,848
	DESV. PAD.	17,43	24,03	24,03	
	MEDIANA	74,46	71,13	76,63	

Fonte: o autor (2014)

Comparando-se os resultados verificados com o que é sugerido pela literatura, nota-se que utilizar dados de vendas iniciais permite que a previsão de demanda tenha melhor desempenho preditivo, assim como afirmam Mattila (1999), Fisher et al. (2000) e Fisher (2009). Além disso, o método como proposto se adéqua à realidade dos varejistas de Moda Rápida. Considerando que o planejamento do sortimento de produtos desses varejistas prevê um número elevado de artigos e variações (CACHON; SWINNEY, 2011; GHEMAWAT; NUENO, 2003), o modelo incorpora quantos produtos, artigos e variações forem necessários. E não somente o número de artigos é uma dificuldade, mas também que os produtos são diferentes a cada ano e cada estação. O modelo supera essa dificuldade, alcançando os resultados demonstrados.

6.4 IMPLICAÇÕES GERENCIAIS

O modelo de previsão ora proposto apresenta maior acuracidade que o modelo original utilizado. Preferencialmente as decisões quanto às ações baseadas nas informações coletadas a partir do modelo deverão ser realizadas por um especialista. Isso porque o modelo não fornece

uma indicação da ação a ser tomada, mas sim a previsão de demanda em si. No entanto, a informação fornecida pelo modelo, a previsão de demanda ajustada, é a informação que um especialista necessita para adequar o estoque e as reposições ao ritmo de venda. Isso significa que o modelo ora proposto tem potencial para reduzir as duas perdas que afetam diretamente a margem de lucro da operação do varejo. Tanto a perda de vendas por falta de produtos em estoque como a redução de margem por venda de produtos em liquidação podem ser reduzidas.

O modelo proposto pode ser utilizado como uma ferramenta para varejistas que adotem o modelo de negócio de Moda Rápida. Tendo em vista que os varejistas de Moda Rápida buscam estar aptos a responderem rapidamente às tendências do mercado, lançam novos produtos frequentemente. O modelo proposto está apto a realizar previsões com a mesma acuracidade para produtos novos ou já comercializados. Assim, tende a atender as necessidades dessas empresas. Também é importante notar que diversos trabalhos afirmam que as previsões poderiam ser melhoradas se fossem atualizadas com base nas vendas iniciais e com o monitoramento da acuracidade das previsões. E que essa prática, utilizada pela espanhola Zara e pela japonesa WorldCo, tem levado as empresas a alcançar resultados melhores que a média do mercado. No entanto, os trabalhos não apresentam clara e objetivamente como fazê-lo, como utilizar as informações e gerar a nova previsão de demanda. O presente trabalho e o modelo proposto trazem um método de como utilizar essas informações de forma vantajosa, buscando apresentar de forma clara como alcançou esse objetivo.

É importante notar que para muitos varejistas a previsão de demanda se baseia no instinto de alguns especialistas e não no uso sistemático de dados. O que o presente modelo propõe é a utilização de ambas as fontes de informação para gerar a previsão de demanda. Desperdiçar o conhecimento acumulado dos especialistas é desperdiçar conhecimento. Assim, o modelo é potencializado pelo uso sistemático de dados de maneira razoavelmente simples. E a simplicidade tende a favorecer o entendimento e a aceitação do modelo por parte dos especialistas e executivos das empresas em uma aplicação real. Modelos Bayesianos fazem exatamente isso, utilizar essas duas fontes de conhecimento. Apesar dos defensores apontarem que os resultados são melhores, esses modelos perdem no quesito simplicidade.

Considerar os outros fatores do modelo conceitual juntamente com as ações possíveis a partir do ajuste da previsão podem tornar a utilização do modelo ainda mais vantajosa. O modelo proposto tem seu foco delimitado à acuracidade da previsão de demanda, bem como às decisões de sortimento de produtos e às quantidades a serem mantidas em estoque dos

produtos definidos pelo sortimento adotado. No entanto, os resultados obtidos pela utilização do modelo podem ser extrapolados para os outros fatores do modelo conceitual. Obviamente, uma melhora na acuracidade da previsão de demanda como obtido com a utilização do modelo proposto proporcionará a capacidade de tomadas de decisão de mais qualidade. Assim, as quantidades a serem compradas e as decisões de sortimento de produtos a serem ofertadas tenderão a ser melhores. Mas, além disso, a informação fornecida pela combinação da previsão de longo prazo com a previsão de curto prazo permite que tanto decisões sobre os fatores estruturais como as outras decisões operacionais do varejo possam ser analisadas e discutidas.

6.4.1 Planejamento de Estoques e Velocidade da Cadeia de Suprimentos

Os fatores estruturais propostos no modelo conceitual podem ser modificados sem a utilização de um modelo de previsão de demanda. Melhorar tanto o planejamento de estoques como a velocidade da cadeia de suprimentos tendem a melhorar o sistema como um todo. No entanto, é interessante descrever as modificações possíveis a partir da aplicação de um modelo que utiliza dados das vendas iniciais, como faz o modelo proposto.

A *Quick Response* e a *Accurate Response* buscam melhorar a capacidade de resposta e a flexibilidade da cadeia de suprimentos. Enfatizam a flexibilidade e a velocidade para atender exigências que mudam constantemente num mercado competitivo. Uma de suas bases é postergar a decisão de produzir até que a previsão de demanda possa ser validada por dados do ponto de venda, no último momento possível (LOWSON et al., 1999). Na mesma linha, um dos pilares da Moda Rápida é a capacidade de reagir às tendências e melhorar os tempos de resposta (HAYES; JONES, 2006). Ou seja, melhorar os tempos de reação e resposta, aumentando a flexibilidade e a velocidade da cadeia de suprimentos é algo estimulado por várias técnicas e ferramentas. Uma das maneiras de alcançar esse objetivo é com a redução do tempo de atravessamento.

No entanto, para explorar um tempo de atravessamento baixo, é necessário que haja troca de informação sobre a demanda entre o cliente e o fornecedor. Os resultados da redução do tempo de atravessamento são limitados pela qualidade da informação de demanda compartilhada com o fornecedor e pelo momento em que a informação é compartilhada (DE TREVILLE et al., 2004). Por isso, além de obter informação de maior qualidade, fornecida pelo modelo ora proposto, é preciso compartilhar a informação obtida com o fornecedor. Por outro lado, a redução do tempo de atravessamento sem parcimônia pode levar a aumentos de

custos. O conceito de *Leagile* propõe que se busquem reduções de custo a jusante na cadeia de suprimentos, e agilidade a montante, definindo um ponto de desconexão (HOEK, 2000; MASON-JONES et al., 2000; NAYLOR et al., 1999).

Assim, pode-se trabalhar no sentido de reduzir o tempo de atravessamento de produção, que atualmente oscila em torno de 60 dias para o maior fornecedor da rede de varejo. Diversas podem ser as estratégias adotadas para tanto. Redução de tamanho de lote gerará redução direta no tempo de atravessamento. Poderá incorrer em aumento de custo, entretanto. Também o *postponement* proposto pela Moda Rápida (GHEMAWAT; NUENO, 2003), obtendo estoques de matérias-primas e não de produtos prontos e produzindo a quantidade total planejada somente após a confirmação da demanda real. Confirmação possível utilizando o modelo de demanda ora proposto. Essas reduções permitiriam a utilização de reposições dos produtos cuja demanda tenha sido identificada como maior do que a cobertura de estoques existente. O autor estima que se poderia reduzir o tempo de atravessamento para 30 dias, caso as matérias primas já estivessem disponíveis em estoque como proposto. Isso porque, em média, 20 dias do tempo de atravessamento são relativos à espera do material. Outros 20 dias são relativos a fila para início da produção, e os 20 dias restantes são relacionados ao tempo após o início da produção. É provável que com adequações no sistema produtivo, reduções no tamanho de lote permitam que esse tempo seja reduzido para 20 ou 25 dias, considerando o tempo na fila e o tempo para produção em si. Reduções para tempos menores que esses provavelmente implicariam em ociosidade no sistema produtivo em determinados momentos. E em consequência em maiores custos. Considerando a realidade e o proposto pelo conceito *Leagile*, a jusante o foco deve ser a redução de custo prioritariamente ao aumento de flexibilidade, ou seja, deve ser obtida toda a flexibilidade possível desde que ela não incorra em aumento de custos.

Além de modificações no ambiente de produção, são possíveis modificações na distribuição dos produtos. A utilização de um centro de distribuição poderia realizar os ajustes necessários atendendo em parte a flexibilidade e velocidade na reposição necessárias. No entanto incorrendo em um custo elevado ao sistema. Uma alternativa seria utilizar a própria fábrica como centro de distribuição. Tanto utilizar centro de distribuição como manter estoque na fábrica trariam adicionalmente o ganho da agregação das flutuações de demandas entre as lojas, reduzindo o erro das previsões. Essa é exatamente a primeira proposta de adequação do sistema de distribuição proposta pela TOC, trazer o estoque central para o mais próximo da fábrica (SCHRAGENHEIM, 2010). Mesmo assim, os custos logísticos da gestão do estoque e a definição dos lotes econômicos de reposição precisariam ser estudados e dimensionados. E

na prática, o estoque da loja estaria sendo deslocado para a fábrica, transferindo o risco do mesmo da loja para a fábrica.

O risco que afeta a decisão de quanto manter em estoque está associado ao risco de sobragem produtos em estoque ou faltarem produtos para venda. Atualmente, os dois riscos afetam diretamente o varejista. Mas, movendo o estoque para a fábrica, o risco de sobragem produtos em estoque seria movido para a fábrica. Então, para mitigar o risco da fábrica, menores estoques deveriam ser mantidos. No entanto, menores estoques implicam em menor cobertura de vendas e maior risco de perda de vendas. A redução do tempo de atravessamento somado ao aumento de capacidade produtiva, mesmo que ociosa, poderia trazer soluções para esse conflito. Essa ação manteria os estoques baixos e permitiria que rapidamente as faltas nos estoques fossem repostas. No entanto, isso resultaria em um aumento de custos, o que deveria ser evitado, dada a sensibilidade ao aumento de custos existente no mercado calçadista, em particular nesse posicionamento de negócio (STÜKER et al., 2013). Então, para gerir o risco dos estoques e possibilitar o avanço de uma solução que não aumentasse custos, uma divisão de riscos poderia ser realizada, por meio de vendas com contratos de risco. Caso houvesse excesso de demanda e capacidade adicional fosse necessária, acima do volume planejado, poderia haver um preço prêmio, já que horas extras ou capacidade em outras empresas tem custo maior. Por outro lado, caso houvesse sobra de produtos em estoques, descontos poderiam ser concedidos por parte da fábrica como forma de acelerar as vendas. Nesse caso, o objetivo acima do lucro realizado na estação seria, no longo prazo, a sobrevivência do sistema às oscilações do mercado.

Paralelamente às ações possíveis, o modelo exige que exista uma semana de observação da demanda, ou seja $t+1$. Considerando que a semana seguinte seja utilizada para coleta e análise dos dados, em $t+2$ uma decisão relacionada a cada produto para cada loja poderá ser tomada. Assim, uma ponderação do envio de produtos poderia ser realizada. Uma parte dos produtos produzidos poderiam ser enviados para as lojas, atendendo apenas uma parte da cobertura de estoques prevista pela previsão de demanda atual da rede. Uma proposta simples seria a metade do previsto. Então, o restante dos produtos poderia ser redistribuído de acordo com a previsão do modelo ora proposto. Por outro lado, a TOC propõe que se defina a frequência de reposições de acordo com a capacidade de resposta do sistema e da demanda. Também caracteriza os tempos de atravessamento, o de pedido, o de produção e o de transporte (SCHRAGENHEIM, 2010). Como a demanda poderia ser conhecida a partir do modelo proposto, em $t+2$ os produtos podem passar a serem repostos com uma frequência determinada em função somente do tempo atravessamento de transporte. A opção de

abastecer ou não o estoque pode ser feita de acordo com o desempenho das vendas na primeira semana. Dessa forma, um determinado produto poderia ser repostado semanalmente, de acordo com o consumo, até o término do estoque. Ou, se o mesmo apresentasse bom desempenho de vendas, novos lotes poderiam ser fabricados, abastecendo o estoque junto à fábrica. Isso prolongaria o período em que as reposições semanais poderiam ser possíveis, chegando ao limite de fazê-lo até o fim da estação. De qualquer forma, ou a rede de varejo deveria passar a utilizar um centro de distribuição ou a parte do estoque que não fosse enviada diretamente para a loja ficaria na fábrica, como já mencionado anteriormente.

6.4.3 Quantidades em estoque e Sortimento de produtos

A tomada de decisão sobre utilizar ou não um segundo envio de produtos necessariamente deveria ser tomada por um especialista. As informações fornecidas pelo modelo seriam utilizadas mais como uma ferramenta de auxílio à tomada de decisão do que propriamente um modelo em si. O tomador de decisão se depararia com três condições para cada produto, a cada loja individualmente: (1) as vendas ocorreram de acordo com o previsto; (2) as vendas ocorreram abaixo do previsto; ou (3) as vendas ocorreram acima do previsto. Caso as vendas tenham ocorrido de acordo com o esperado, o restante do estoque ainda na fábrica não necessitaria de ajustes. No entanto, caso as vendas venham a ocorrer abaixo do esperado, a quantidade a ser enviada da fábrica para a loja no segundo envio poderia ser reduzida. Uma possibilidade de redução seria definir a quantidade a ser enviada pela subtração do estoque inicial da quantidade sugerida pela previsão para oito semanas. Por outro lado, caso a venda fosse superior ao previsto, a quantidade a ser enviada da fábrica para a loja poderia ser aumentada. A quantidade a ser enviada poderia ser obtida pelo valor previsto quando o modelo não está limitado ao estoque, como se o estoque fosse infinito e a demanda se comportasse de maneira constante.

Após as análises por produto para todas as lojas, uma análise por produto de maneira geral deveria ser realizada. De maneira semelhante ao realizado na etapa anterior, caso não houvessem sobras nem faltas, nenhuma ação seria necessária. Por outro lado, caso houvesse uma demanda maior que a quantidade de produtos em estoque, um pedido de reposição se faria necessário. E dependendo do planejamento de vendas, até mesmo uma quantidade maior de produtos poderia ser produzida, já prevendo as vendas do período natalino. Nessa situação as modificações buscando aumento de flexibilidade e velocidade necessariamente deveriam estar colocadas em prática para que se perdesse a menor quantidade de vendas possível. Em

uma situação de demanda acima da capacidade instalada, o preço prêmio poderia ser acionado conforme contrato anteriormente sugerido. No entanto, caso houvesse sobras de produtos no estoque da fábrica após a análise por produto de todas as lojas em conjunto, o desconto previsto por contrato poderia ser acionado. Com isso, a demanda dos produtos não populares seria acelerada pelos descontos e haveria uma perda de resultado financeiro. Por outro lado, com a reposição dos produtos populares, a demanda de substituição diminuirá. E com a redução da demanda de substituição, os 40% de perda sugeridos por Mattila (1999) – ele verificou que 60% da demanda original é absorvida em outros produtos de moda como demanda de substituição – seriam também reduzidos. Com a redução da perda e o aumento do giro de estoques propiciado pelos descontos concedidos, o resultado tenderia a ser maior.

Obviamente a ideia de utilizar informações sobre a demanda atualizada para modificar os níveis de estoque de lojas individualmente, ou em conjunto de lojas que serão abastecidas no meio da estação e realizar acordos de fornecimento flexíveis que permitam que a quantidade de reabastecimento total possa ser ajustada no meio da estação (AGRAWAL; SMITH, 2009b) são ideias já propostas e defendidas. Assim, as questões “porque” e “o que” já estão respondidas. As sugestões feitas buscam responder “como” fazê-lo.

Poder-se-ia aprender sobre as características mais populares para ajustar o sortimento de produtos ofertados. Verificar as características comuns dos produtos populares, como cor, material, os níveis de preço, venda por subgrupo de produto pode permitir correções antes mesmo do primeiro envio, na elaboração dos pedidos de compra realizados pelos especialistas. Obviamente, as características comuns aos produtos não populares deveriam ser evitadas.

6.4.4 Preço e Operação da Loja

As políticas de preços são um componente fundamental das operações de empresas de manufatura e serviços, provavelmente porque o preço é uma das variáveis mais eficazes a serem manipuladas pelos gestores para encorajar ou desencorajar a demanda no curto prazo (BITRAN; CALDENTEY, 2003). A otimização da precificação dinâmica, um ramo da gestão de receitas, investiga o preço como variável-chave de decisão em um ambiente de negócios dinâmico. Em particular, estuda como operacionalizar as decisões de preços, considerando, por exemplo, estoques e seu nível ao longo do tempo (WHANG, 2009).

Assim, para os produtos que estiverem com o nível de estoque elevado na fábrica, após a análise da demanda realizada por produto, o preço poderia ser reduzido para encorajar

a demanda no curto prazo. A operação da loja poderia ser ajustada a promover esses produtos, gerando promoções durante a coleção. Essa ação permitiria que esses produtos que apresentam algum tipo de desalinhamento sejam rapidamente retirados da oferta de produtos. Essa retirada daria espaço para a promoção dos produtos populares, também identificados pelo modelo.

7 CONSIDERAÇÕES FINAIS

Para produtos de moda, é sabido que existem condições que dificultam a previsão de vendas e a gestão de estoques. A tomada de decisão quanto às quantidades e variedades de produtos antes do início da estação de vendas, bem como elas serem embasadas basicamente em dados qualitativos e questões subjetivas sobre produtos são duas dessas condições. Somada a essa condição, as restrições crescentes (numerosos e novos itens, curto ciclo de vida dos produtos) tornam a previsão de demanda um desafio ainda maior.

O objetivo geral da presente pesquisa foi de propor um modelo de previsão de demanda baseado no aprendizado com as vendas iniciais para uma rede de varejo calçadista. O modelo de previsão de demanda foi construído em três etapas: a escolha dos objetos de análise utilizando análise de aglomerados; o modelo de previsão de demanda de longo prazo; e o modelo de previsão de demanda de curto prazo. A melhor maneira de aglomerar lojas para realização de testes e previsões de demanda é de acordo com o comportamento de suas vendas, como foi realizado. Esse agrupamento visa reduzir o tempo para realizar a previsão de demanda, bem como o planejamento posterior. Então, foram realizadas as duas etapas que tratam da previsão em si: (i) a primeira que utilizou dados históricos de vendas agregados por subgrupo de produtos, por loja; e (ii) a segunda que utilizou dados das vendas iniciais para desagregar a previsão por subgrupo na previsão por produtos e cores. Para gerar a previsão de longo prazo por subgrupo de produtos foi utilizado o modelo logístico. A Razão de Incremento Semanal (RIS), que é a previsão de vendas por semana dividida pela quantidade de produtos vendidos, foi utilizada como dados de entrada para decompor a previsão em produtos e cores. Além dessa informação, são entradas a quantidade vendida na primeira semana e a quantidade de produtos em estoque. A partir da modificação do cálculo da cobertura de estoques para incluir o RIS, tem-se a previsão de demanda atualizada. A previsão também considera a demanda de substituição e a quebra de grade.

A análise de aglomerados foi realizada com 8 lojas. Para que se encontrassem resultados significativos, foi necessário dividir as variáveis por subgrupos de produtos e por ano. Somente puderam ser consideradas como aglomerados aquelas lojas que se mantiveram nos mesmos aglomerados em todas as análises. Foram encontrados de três a cinco aglomerados. Três lojas atenderam esse critério, no entanto uma das lojas sozinha em um aglomerado e as outras duas no mesmo. Foram realizados testes para verificar se utilizando o modelo de previsão de longo prazo de uma loja para prever as vendas da outra loja os resultados seriam aceitáveis. Foi verificado que a variação média foi de -0,78% no MSE e

1,61% no MAPE. Adicionalmente, é possível associar uma loja nova a um dos aglomerados identificados e aplicar o modelo de previsão à mesma. Para isso é necessário que se consulte um especialista, mas essa competência torna o modelo mais abrangente.

As métricas para medição do desempenho preditivo do modelo de longo prazo utilizadas foram o MSE e o MAPE. Adicionalmente, para comparação dos resultados da previsão da venda total com a prevista foi utilizada a métrica APE. O modelo de longo prazo foi aplicado para três lojas, e três subgrupos de produtos. Para o subgrupo de rasteiras, o MSE médio entre as lojas foi de 5812,64; o MAPE médio foi de 33,04 e o APE médio da venda total foi de 4,36. Para o subgrupo de sapatilhas, o MSE médio foi de 11517,54; o MAPE médio foi de 45,43 e o APE médio da venda total foi de 51,40. Já para o subgrupo de sapatilhas de tecido o MSE médio foi de 1147,00; o MAPE médio foi de 41,74 e o APE médio foi de 4,61. O modelo ora proposto se mostrou adequado para prever as vendas dos subgrupos de rasteiras e de sapatilhas de tecido. No entanto, não apresentou resultados satisfatórios para o subgrupo de sapatilhas.

As métricas para medição do desempenho preditivo utilizadas foram o APE e o MAPE* considerando seis e oito semanas como horizonte de previsão. A previsão de demanda foi realizada para 50 produtos, para o subgrupo de rasteiras em uma das lojas analisadas. O desempenho do modelo ora proposto foi superior em todas as métricas de desempenho utilizadas. O desempenho do modelo conforme a métrica APE para seis semanas de horizonte de previsão foi de 55,199 para o modelo proposto e de 207,511 para o modelo de previsão original. Para a mesma métrica em oito semanas de horizonte de previsão foi de 51,232 para o modelo e de 93,212 para o modelo de previsão original. Conforme a métrica MAPE* para seis semanas de horizonte de previsão, o modelo proposto apresentou resultados de 87,598 se comparando com os 239,777 para o modelo de previsão original. E a MAPE* para oito semanas de horizonte de previsão apresentou resultado de 88,454 para o modelo proposto e de 167,515 para o modelo de previsão original. A análise dos dados permitiu identificar a ocorrência do fenômeno de demanda de substituição. No entanto, os testes realizados para verificarem a sensibilidade do modelo à demanda de substituição demonstraram que o modelo apresentou baixa sensibilidade à isso. O mesmo resultado pode ser percebido para a quebra de grade. Além disso, percebeu-se que a RIS, como proposta no presente trabalho, representa de maneira adequada a variação sazonal que ocorre ao longo da estação de vendas. A quantidade de produtos vendidos aumenta por volta de 8 a 10 vezes mais que a RIS, já que a mesma é ponderada pela média de produtos vendidos, que também

aumenta paralelamente ao aumento do volume de vendas. Pode-se também perceber que o modelo proposto é uma boa alternativa de previsão de demanda à indústria de Moda Rápida.

Entende-se que o trabalho atendeu aos objetivos propostos, na medida em que propôs um modelo de previsão de demanda que utilizou os dados de vendas iniciais e que teve desempenho superior ao modelo original. A acuracidade do modelo proposto pode ser verificada, bem como a viabilidade do mesmo pode ser analisada em conjunto com as implicações gerenciais e práticas que a utilização do modelo fornece.

Considerando as limitações do presente trabalho, o modelo não pode ser considerado como validado. Como foi aplicado a somente um caso, não se pode esperar que os mesmos resultados sejam encontrados em casos diferentes. No entanto, os resultados alcançados podem ser úteis à empresa de onde os dados foram coletados. Além de que a continuidade dos estudos pode refinar o método, tornando-o mais robusto.

Como sugestões para futuros trabalhos, numa primeira instância são propostos aprimoramentos para o modelo ora proposto. No modelo de previsão de longo prazo, poderiam ser utilizados ou testados paralelamente diferentes modelos de previsão, como ARIMA e redes neurais. Para o modelo de previsão de curto prazo, poder-se-ia buscar a automatização da geração da previsão diretamente pelo software de gestão de estoques que a empresa utiliza, diminuindo o tempo e o trabalho necessários. Também outras abordagens poderiam ser testadas para realizar a decomposição da previsão para os produtos, como o método *neurofuzzy*. Assim como podem ser buscadas abordagens alternativas para a modelar o fenômeno da demanda de substituição, considerando a substituição entre todo grupo de produtos e também entre grupo de produtos. Sugere-se que variáveis *dummy* sejam utilizadas buscando expressar o nível de estoque no momento em que o modelo está sendo analisado, como alternativa à utilização de todos os modelos sendo vendidos e seus estoques no momento da previsão de curto prazo. A aplicação do modelo proposto à prática, tomando decisões com base nas informações do modelo, também é sugerida. Adicionalmente, informações de vendas *online* poderiam também ser utilizadas no modelo. Tanto informações de vendas realizadas como informações de acessos realizados à cada produto, mesmo sem compra.

A partir das implicações gerenciais, também emergem sugestões para futuros trabalhos baseados no modelo ora proposto. Considerando que a tomada de decisão com base nas informações fornecidas pelo modelo é aconselhada a ser feita por um especialista, sugere-se a integração da previsão com uma previsão de demanda por julgamento, definindo como, quando e onde o especialista deveria atuar. Além disso, sugere-se a criação de um método

AHP para organizar e guiar a tomada de decisão possível a partir da utilização do modelo, como descrito nas implicações gerenciais. Considerando a precificação dinâmica sugerida para produtos com desempenho ruim, é necessário criar um modelo para definir o preço a ser cobrado, considerando as restrições de tempo para redução do estoque e ganho.

Também se sugere que seja aprofundada a compreensão das relações entre os fatores críticos de sucesso e as decisões operacionais do varejo. Modelos que considerem ou adicionem outros fatores do modelo conceitual podem agregar conhecimento. Como exemplo, pode-se citar a adição de cenários de previsão de demanda ou resultado considerando precificação dinâmica. Bem como modelos que considerem mudanças na velocidade da cadeia de suprimentos, verificando custos versus ganhos. Também podem ser explorados os benefícios e dificuldades que o aumento da velocidade da cadeia de suprimentos e da flexibilidade geram ao sistema operando em conjunto com um método de previsão de demanda adaptativo, como o do presente trabalho.

Observou-se que para o caso de diversos produtos populares, a venda é limitada pela compra, ou seja, muitos desses produtos acabam rapidamente. Ao acabarem rapidamente, a demanda acaba não sendo totalmente atendida. Por outro lado, a previsão de demanda é realizada com base nas vendas realizadas. A previsão ou o modelo de previsão não tem como perceber e modelar essa diferença entre a demanda que se tornou compra e a demanda não atendida. Sugere-se então que sejam pesquisados métodos e técnicas para identificar e quantificar esse *gap*.

Também se sugere que se pesquise um método para identificar os atributos que estejam associados aos produtos populares (cor, artigo, estilo, preço, entre outros possíveis) e que quantifique de alguma forma o efeito que os atributos estejam gerando nas vendas. Essa informação pode ser utilizada para modificar produtos que não estejam tendo bom desempenho, criando alternativas à reposição de produtos populares para sustentar a venda.

REFERÊNCIAS BIBLIOGRÁFICAS

ABERNATHY, F. H. et al. Retailing and supply chains in the information age. **Technology in Society**, v. 22, n. 1, p. 5–31, jan. 2000.

ABICALÇADOS. **Cartilha Indústria de Calçados do Brasil 2012**. [s.l: s.n.].

ABICALÇADOS. **Importação Brasileira de Calçados 2013**. [s.l: s.n.].

ABICALÇADOS. **Exportação Brasileira de Calçados 2013**. [s.l: s.n.].

ABICALÇADOS. **Evolução do Emprego na Indústria de Calçados**. [s.l: s.n.].

AGRAWAL, N.; SMITH, S. **Retail Supply Chain Management**. New York: Springer Science + Business Media, 2009a.

AGRAWAL, N.; SMITH, S. Multi-location Inventory Models for Retail Supply Chain Management. In: AGRAWAL, N.; SMITH, S. (Eds.). **Retail supply chain management**. New York: Springer Science + Business Media, 2009b.

AGRAWAL, N.; SMITH, S. A. Optimal inventory management for a retail chain with diverse store demands. **European Journal of Operational Research**, v. 225, n. 3, p. 393–403, mar. 2013.

AKSOY, A.; OZTURK, N.; SUCKY, E. A decision support system for demand forecasting in the clothing industry. **International Journal of Clothing Science and Technology**, v. 24, n. 4, p. 221–236, 2012.

ANDRAWIS, R. R.; ATIYA, A. F.; EL-SHISHINY, H. Combination of long term and short term forecasts, with application to tourism demand forecasting. **International Journal of Forecasting**, v. 27, n. 3, p. 870–886, jul. 2011.

ARMSTRONG, J. **Principles of forecasting: a handbook for researchers and practitioners**. Dordrecht: Kluwer Academic Publishers, 2001.

ARMSTRONG, J.; GREEN, K. **Demand forecasting: Evidence-based methods**Woe. [s.l: s.n.]. Disponível em: <<http://forecastingprinciples.com/paperpdf/DemandForecasting.pdf>>. Acesso em: 23 maio. 2013.

AU, K.-F.; CHOI, T.-M.; YU, Y. Fashion retail forecasting by evolutionary neural networks. **International Journal of Production Economics**, v. 114, n. 2, p. 615–630, ago. 2008.

BABUŠKA, R.; VERBRUGGEN, H. Neuro-fuzzy methods for nonlinear system identification. **Annual Reviews in Control**, v. 27, n. 1, p. 73–85, jan. 2003.

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

BARNES, L.; LEA-GREENWOOD, G. Fast fashioning the supply chain: shaping the research agenda. **Journal of Fashion Marketing and Management**, v. 10, n. 3, p. 259–271, 2006.

BELL, D.; BONFRER, A.; CHINTAGUNTA, P. Recovering SKU-level Preferences and Price Sensitivites from Market Share Models Estimated on Item Aggregates. **Journal of Marketing Research**, v. 42, n. 2, p. 169–182, 2005.

BITRAN, G.; CALDENTHEY, R. An overview of pricing models for revenue management. **Manufacturing & Service Operations Management**, v. 5, n. 3, p. 203–229, 2003.

BLACKSTONE JR, J. H. A Review of Literature on Drum-Buffer-Rope, Buffer Management and Distribution. In: **Theory of Constraints Handbook**. New York: McGraw-Hill, 2010. p. 145–173.

BODGER, P. S.; TAY, H. S. Logistic and energy substitution models for electricity forecasting: A comparison using New Zealand consumption data. **Technological Forecasting and Social Change**, v. 31, n. 1, p. 27–48, mar. 1987.

BOX, G.; JENKINS, G.; REINSEL, G. **Time Series Analysis - Forecasting and Control**. 3.ed. ed. New Jersey: Prentice Hall, 1994.

BRITO, E.; VIEIRA, V.; ESPARTEL, L. A pesquisa na área do varejo: reflexões e provocações. **Revista de Administração de Empresas**, v. 51, n. 6, p. 522–527, 2011.

BRUCE, M.; DALY, L.; TOWERS, N. Lean or agile: A solution for supply chain management in the textiles and clothing industry? **International Journal of Operations & Production Management**, v. 24, n. 2, p. 151–170, 2004.

CACHON, G. P.; SWINNEY, R. The Value of Fast Fashion: Quick Response, Enhanced Design, and Strategic Consumer Behavior. **Management Science**, v. 57, n. 4, p. 778–795, 4 mar. 2011.

CARO, F. et al. Zara Uses Operations Research to Reengineer Its Global Distribution Process. **Interfaces**, v. 40, n. 1, p. 71–84, 2 fev. 2010.

CARO, F.; GALLIEN, J. Dynamic Assortment with Demand Learning for Seasonal Consumer Goods. **Management Science**, v. 53, n. 2, p. 276–292, 1 fev. 2007.

CARO, F.; GALLIEN, J. Inventory Management of a Fast-Fashion Retail Network. **Operations Research**, v. 58, n. 2, p. 257–273, 12 ago. 2010.

CARO, F.; GALLIEN, J. Clearance Pricing Optimization for a Fast-Fashion Retailer. **Operations Research**, v. 60, n. 6, p. 1404–1422, 17 dez. 2012.

CARO, F.; MARTINEZ-DE-ALBENIZ, V. The Impact of Quick Response in Inventory-Based Competition. **Manufacturing & Service Operations Management**, v. 12, n. 3, p. 409–429, 14 set. 2009.

CHEN, F. L.; OU, T. Y. Sales forecasting system based on Gray extreme learning machine with Taguchi method in retail industry. **Expert Systems with Applications**, v. 38, n. 3, p. 1336–1345, mar. 2011.

CHILDERHOUSE, P.; TOWILL, D. Engineering supply chains to match customer requirements. **Logistics Information Management**, v. 13, n. 6, p. 337–346, 2000.

CHING-CHIN, C. et al. Designing a decision-support system for new product sales forecasting. **Expert Systems with Applications**, v. 37, n. 2, p. 1654–1665, mar. 2010.

CHOI, T. et al. Color trend forecasting of fashionable products with very few historical data. **Systems, Man, and ...**, v. 42, n. 6, p. 1003–1010, nov. 2012.

CHOI, T. M.; CHIU, C. H.; TO, K. M. C. A fast fashion safety-first inventory model. **Textile Research Journal**, v. 81, n. 8, p. 819–826, 15 dez. 2010.

CHOI, T.-M. et al. Fast fashion sales forecasting with limited data and time. **Decision Support Systems**, v. 59, p. 84–92, mar. 2014.

CHOPRA, S.; MEINDL, P. **Gerenciamento da Cadeia de Suprimentos: estratégia, planejamento e operações**. São Paulo: Prentice Hall, 2003.

CHOY, K.; LEE, W.; LO, V. Design of an intelligent supplier relationship management system: A hybrid case based neural network approach. **Expert Systems with Applications**, v. 24, n. 2, p. 225–237, 2003.

CHRISTOPHER, M.; LOWSON, R.; PECK, H. Creating agile supply chains in the fashion industry. **International Journal of Retail & Distribution Management**, v. 32, n. 8, p. 367–376, 2004.

CHU, W.-L. et al. Diffusion of mobile telephony: An empirical study in Taiwan. **Telecommunications Policy**, v. 33, n. 9, p. 506–520, out. 2009.

CHUNG, C.; NIU, S.-C.; SRISKANDARAJAH, C. A Sales Forecast Model for Short-Life-Cycle Products: New Releases at Blockbuster. **Production and Operations Management**, v. 21, n. 5, p. 851–873, 29 set. 2012.

CORREA, J. **Optimization of a fast-response distribution network**. [s.l.] Massachusetts Intitute of Technology, 2007.

DANA, J.; DAWES, R. M. The Superiority of Simple Alternatives to Regression for Social Science Predictions. **Journal of Educational and Behavioral Statistics**, v. 29, n. 3, p. 317–331, 1 jan. 2004.

DANTAS, O. D. et al. **COMPARAÇÃO DOS MÉTODOS GRG2 (SOLVER DO EXCEL) E DOWNHILL SIMPLEX PARA A PARAMETRIZAÇÃO DA FUNÇÃO BETAXXXIX SBPO**. *Anais...2007*

DAS, P.; CHAUDHURY, S. Prediction of retail sales of footwear using feedforward and recurrent neural networks. **Neural Computing and Applications**, v. 16, n. 4-5, p. 491–502, 16 dez. 2006.

DE TREVILLE, S.; SHAPIRO, R. D.; HAMERI, A.-P. From supply chain to demand chain: the role of lead time reduction in improving demand chain performance. **Journal of Operations Management**, v. 21, n. 6, p. 613–627, jan. 2004.

DEHORATIUS, N.; RAMAN, A. Store Manager Incentive Design and Retail Performance: An Exploratory Investigation. **Manufacturing & Service Operations Management**, v. 9, n. 4, p. 518–534, 1 jan. 2007.

DEHORATIUS, N.; TON, Z. The Role of Execution in Managing Product Availability. In: AGRAWAL, N.; SMITH, S. (Eds.). **Retail supply chain management**. New York: Springer Science + Business Media, 2009.

DEPECON. **Panorama da Indústria de Transformação Brasileira**. São Paulo: [s.n.].

DHAR, V.; STEIN, R. **Seven methods for transforming corporate data into business intelligence**. New Jersey: Prentice Hall, 1997. p. 269

DIAS, M. A. P. **Administração de materiais: uma abordagem logística**. 4.ed. ed. São Paulo: Atlas, 2009.

EFENDIGIL, T.; ÖNÜT, S.; KAHRAMAN, C. A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. **Expert Systems with Applications**, v. 36, n. 3, p. 6697–6707, abr. 2009.

ENDERS, W. **Applied Econometric Time Series**. 3.ed. ed. [s.l.] Wiley, 2010. p. 517

FIGUEIREDO, M.; GOMIDE, F. Design of fuzzy systems using neurofuzzy networks. **IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council**, v. 10, n. 4, p. 815–27, jan. 1999.

FILIPPINI, R. Operations management research: some reflections on evolution, models and empirical studies in OM. **International Journal of Operations & Production Management**, v. 17, n. 7, p. 655–670, 1997.

FISHER, M. et al. Making supply meet demand in an uncertain world. **Harvard Business Review**, p. 83–93, 1994.

FISHER, M. Rocket Science Retailing: The 2006 Philip McCord Morse Lecture. **Operations Research**, v. 57, n. 3, p. 527–540, 27 jun. 2009.

FISHER, M. L. What is the right supply chain for your product? **Harvard Business Review**, 1997.

FISHER, M. L.; RAMAN, A.; MCCLELLAND, A. Rocket science retailing is almost here—Are you ready? **Harvard Business Review**, v. 78, n. 4, p. 115–124, 2000.

- FISHER, M.; RAJARAM, K. Accurate Retail Testing of Fashion Merchandise: Methodology and Application. **Marketing Science**, v. 19, n. 3, p. 266–278, 15 jul. 2000.
- FISHER, M.; RAJARAM, K.; RAMAN, A. Optimizing Inventory Replenishment of Retail Fashion Products. **Manufacturing & Service Operations Management**, v. 3, n. 3, p. 230–241, jun. 2001.
- FISHER, M.; RAMAN, A. Reducing the cost of demand uncertainty through accurate response to early sales. **Operations research**, v. 44, n. 1, p. 87–99, 1996.
- FRANK, C. et al. Forecasting women's apparel sales using mathematical modeling. **International Journal of Clothing Science and Technology**, v. 15, n. 2, p. 107–125, 2003.
- GAMBOA, L. F.; OTERO, J. An estimation of the pattern of diffusion of mobile phones: The case of Colombia. **Telecommunications Policy**, v. 33, n. 10-11, p. 611–620, nov. 2009.
- GAO, Y. et al. A neural-network-based forecasting algorithm for retail industry. **Machine Learning and ...**, n. July, p. 12–15, 2009.
- GAVIN, H. P. **The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems**. [s.l.: s.n.].
- GEWANDSZNAJDER, F. **O que é método científico**. São Paulo: Pioneira, 1989.
- GHEMAWAT, P.; NUENO, J. L. ZARA: Fast fashion. **HBS 703-497**, p. 1–35, 2003.
- GIL, A. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2002.
- GIL, A. **Métodos e técnicas de pesquisa social**. São Paulo: Atlas, 2007.
- GUJARATI, D. N. **Basic Econometrics**. 4.ed. ed. [s.l.] McGraw-Hill, 2004. p. 1002
- GUO, Z. X.; WONG, W. K.; LI, M. A multivariate intelligent decision-making model for retail sales forecasting. **Decision Support Systems**, v. 55, n. 1, p. 247–255, abr. 2013.
- HAIR JR., J. F. et al. **Análise Multivariada de Dados**. 6^a. ed. Porto Alegre: Bookman, 2009. p. 688
- HAMILTON, J. **Time series analysis**. Princeton: Princeton University Press, 1994.
- HANKE, J.; WICHERN, D. **Business Forecasting**. 7. ed. ed. New York: Prentice Hall, 2001.
- HARIJAN, K. et al. Forecasting the diffusion of wind power in Pakistan. **Energy**, v. 36, n. 10, p. 6068–6073, out. 2011.
- HARRISON, A.; CHRISTOPHER, M.; VAN HOEK, R. **Creating the Agile Supply Chain**. London: Institute of Logistics & Transport, 1999.
- HAYES, S. G.; JONES, N. Fast fashion: a financial snapshot. **Journal of Fashion Marketing and Management**, v. 10, n. 3, p. 282–300, 2006.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2.ed. ed. New Jersey: Prentice Hall, 1999. p. 842

HILL, R. M. Applying Bayesian methodology with a uniform prior to the single period inventory model. **European Journal of Operational Research**, v. 98, n. 3, p. 555–562, maio 1997.

HOEK, R. VAN. The thesis of leagility revisited. **International Journal of Agile Management Systems**, v. 2, n. 3, p. 196–201, 2000.

HÖÖK, M. et al. Global coal production outlooks based on a logistic model. **Fuel**, v. 89, n. 11, p. 3546–3558, nov. 2010.

HÜBNER, A. H.; KUHN, H. Retail category management: State-of-the-art review of quantitative research and software applications in assortment and shelf space management. **Omega**, v. 40, n. 2, p. 199–209, abr. 2012.

HUNTER, N. A.; VALENTINO, P. Quick response – ten years later. **International Journal of Clothing Science and Technology**, v. 7, n. 4, p. 30–40, 1995.

IYATOMI, H.; HAGIWARA, M. Adaptive fuzzy inference neural network. **Pattern Recognition**, v. 37, n. 10, p. 2049–2057, out. 2004.

JANG, J. ANFIS: adaptive-network-based fuzzy inference system. **Systems, Man and Cybernetics, IEEE Transactions ...**, v. 23, n. 3, p. 665–685, 1993.

KHAN, O.; CHRISTOPHER, M.; BURNES, B. The impact of product design on supply chain risk: a case study. **International Journal of Physical Distribution & Logistics Management**, v. 38, n. 5, p. 412–432, 2008.

KHAN, O.; CHRISTOPHER, M.; CREAZZA, A. Aligning product design with the supply chain: a case study. **Supply Chain Management: An International Journal**, v. 17, n. 3, p. 323–336, 2012.

KOK, A. G.; FISHER, M. L. Demand Estimation and Assortment Optimization Under Substitution: Methodology and Application. **Operations Research**, v. 55, n. 6, p. 1001–1021, 1 nov. 2007.

KÖK, A.; FISHER, M.; VAIDYANATHAN, R. Assortment planning: Review of literature and industry practice. In: AGRAWAL, N.; SMITH, S. (Eds.). **Retail supply chain management**. New York: Springer Science + Business Media, 2009.

KOSKIVAARA, E. Artificial neural networks in analytical review procedures. **Managerial Auditing Journal**, v. 19, n. 2, p. 191–223, 2004.

KOTLER, P. **Administração de Marketing: edição do novo milênio**. São Paulo: Prentice Hall, 2000.

LAKATOS, E. M.; MARCONI, M. A. **Fundamentos da Metodologia Científica**. São Paulo: Atlas, 1990.

LEE, J.; BOATWRIGHT, P.; KAMAKURA, W. A. A Bayesian Model for Prelaunch Sales Forecasting of Recorded Music. **Management Science**, v. 49, n. 2, p. 179–196, fev. 2003.

LEE, J.; LEE, C.-Y.; LEE, K. S. Forecasting demand for a newly introduced product using reservation price data and Bayesian updating. **Technological Forecasting and Social Change**, v. 79, n. 7, p. 1280–1291, set. 2012.

LEVY, M.; WEITZ, B. A. **Retailing Management**. Boston: McGraw-Hill, 2004.

LIU, N. et al. Sales forecasting for fashion retailing service industry: a review. **Mathematical Problems in ...**, v. 2013, p. 1–9, 2013.

LOWSON, R. H. **Strategic Operations Management: The New Competitive Advantage**. London: Routledge, 2002.

LOWSON, R. H.; KING, R.; HUNTER, N. A. **Quick Response: Managing the Supply Chain to Meet Consumer Demand**. Chichester: John Wiley & Sons, 1999.

MAKRIDAKIS, S. Accuracy measures: theoretical and practical concerns. **International Journal of Forecasting**, v. 9, p. 527–529, 1993.

MAKRIDAKIS, S.; HIBON, M. **Evaluating accuracy (or error) measures** INSEAD. Fontainebleau: [s.n.].

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting methods and applications**. 3. ed. ed. New York: John Wiley & Sons, 1998.

MANEVITZ, L.; BITAR, A.; GIVOLI, D. Neural network time series forecasting of finite-element mesh adaptation. **Neurocomputing**, v. 63, p. 447–463, jan. 2005.

MARTINS, P. G.; ALT, P. R. C. **Administração de Materiais e Recursos Patrimoniais**. 3. ed. ed. São Paulo: Saraiva, 2009.

MASON-JONES, R.; NAYLOR, B.; TOWILL, D. R. Engineering the lean agile supply chain. **International Journal of Agile Management Systems**, v. 2, n. 1, p. 54–61, 2000.

MATTILA, H. **Merchandising strategies and retail performance for seasonal fashion products**. [s.l.] Lappeenranta university of Technology, 1999.

MATTILA, H.; KING, R.; OJALA, N. Retail performance measures for seasonal fashion. **Journal of Fashion Marketing and Management**, v. 6, n. 4, p. 340–351, 2002.

MIGUEL, P. A. C. Adoção do estudo de caso na Engenharia de Produção. In: **Metodologia de pesquisa em Engenharia de Produção e Gestão de Operações**. Rio de Janeiro: Campus, 2010a.

MIGUEL, P. A. C. **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. Rio de Janeiro: Elsevier, 2010b.

MILESKI JUNIOR, A. **Análise de métodos de Previsão de Demanda baseados em séries temporais em uma empresa do setor de perfumes e cosméticos.** [s.l.] Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Pontifícia Universidade Católica do Paraná, Curitiba, 2007.

MIRANDA, L. C. M.; LIMA, C. A. S. On the logistic modeling and forecasting of evolutionary processes: Application to human population dynamics. **Technological Forecasting and Social Change**, v. 77, n. 5, p. 699–711, jun. 2010.

MIRANDA, L. C. M.; LIMA, C. A. S. On the forecasting of the challenging world future scenarios. **Technological Forecasting and Social Change**, v. 78, n. 8, p. 1445–1470, out. 2011.

MONTGOMERY, D.; RUNGER, G. **Applied statistics and probability for engineers.** 3.ed. ed. New York: John Wiley & Sons, 2003.

MORABITO, R.; PUREZA, V. Modelagem e simulação. In: **Metodologia de pesquisa em Engenharia de Produção e Gestão de Operações.** Rio de Janeiro: Campus, 2010.

MORETTIN, P.; TOLOI, C. **Séries Temporais.** 2. ed ed. São Paulo: Atual, 1987.

MOSTARD, J.; TEUNTER, R.; DE KOSTER, R. Forecasting demand for single-period products: A case study in the apparel industry. **European Journal of Operational Research**, v. 211, n. 1, p. 139–147, maio 2011.

NAKANO, D. Métodos de pesquisa adotados na Engenharia de Produção e Gestão de Operações. In: **Metodologia de pesquisa em Engenharia de Produção e Gestão de Operações.** Rio de Janeiro: Campus, 2010.

NAYLOR, B.; NAIM, M.; BERRY, D. Leagility: Integrating the lean and agile manufacturing paradigms in the total supply chain. **International Journal of Production Economics**, v. 62, n. 1-2, p. 107–118, maio 1999.

NI, Y.; FAN, F. A two-stage dynamic sales forecasting model for the fashion retail. **Expert Systems with Applications**, v. 38, n. 3, p. 1529–1536, mar. 2011.

NOREEN, E.; SMITH, D.; MACKEY, J. T. **Teoria das Restrições e suas implicações na contabilidade gerencial: um relatório independente.** 1^a Ed. ed. São Paulo: Educator, 1996.

OHNO, T. **O Sistema Toyota de Produção: Além da Produção em Larga Escala.** Porto Alegre: Bookman, 1997.

PANCHARIYA, P. et al. **Nonlinear system identification using Takagi-Sugeno type neuro-fuzzy model** Second IEEE International Conference on Intelligent Systems. **Anais...**2004Disponível em: <http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1344640>. Acesso em: 14 jun. 2014

PARENTE, J. **Varejo no Brasil.** 1. ed. São Paulo: Atlas, 2000.

PELLEGRINI, F.; FOGLIATTO, F. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Produção**, v. 11, n. 1, p. 43–64, 2001.

QUADDUS, M. A. On applying logistic models in technological forecasting. **Socio-Economic Planning Sciences**, v. 20, n. 4, p. 201–206, jan. 1986.

RAGG, T. et al. Bayesian learning for sales rate prediction for thousands of retailers. **Neurocomputing**, v. 43, n. 1-4, p. 127–144, mar. 2002.

RICHARDSON, R. J. **Pesquisa social: métodos e técnicas**. São Paulo: Atlas, 1999.

RICKMAN, T. A.; COSENZA, R. M. The changing digital dynamics of multichannel marketing: The feasibility of the weblog: text mining approach for fast fashion trending. **Journal of Fashion Marketing and Management**, v. 11, n. 4, p. 604–621, 2007.

SACOMAN, M. A. R. **OTIMIZAÇÃO DE PROJETOS UTILIZANDO GRG , SOLVER E EXCELCOBENGE** - XL Congresso Brasileiro de Educação em Engenharia. **Anais...2012**

SCHRAGENHEIM, A. Supply Chain Management. In: **Theory of Constraints Handbook**. New York: McGraw-Hill, 2010. p. 265–301.

SILVA, E.; MENEZES, E. M. **Metodologia da Pesquisa e Elaboração de Dissertação**. 3. ed. Florianópolis: Laboratório de Ensino a Distância da UFSC, 2001.

STÜKER, T. A.; VAZ, I. E.; SELBITTO, M. A. Importância das dimensões de competição em empresas de uma cadeia de suprimentos da indústria calçadista. **Produção em Foco**, v. 3, n. 2, p. 371–391, 16 dez. 2013.

SUN, Z.-L. et al. Sales forecasting using extreme learning machine with applications in fashion retailing. **Decision Support Systems**, v. 46, n. 1, p. 411–419, dez. 2008.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **Systems, Man and Cybernetics, IEEE ...**, v. SMC-15, n. 1, p. 116–132, jan. 1985.

TANAKA, K. A sales forecasting model for new-released and nonlinear sales trend products. **Expert Systems with Applications**, v. 37, n. 11, p. 7387–7393, nov. 2010.

THOMASSEY, S. Sales forecasts in clothing industry: The key success factor of the supply chain management. **International Journal of Production Economics**, v. 128, n. 2, p. 470–483, dez. 2010.

THOMASSEY, S.; FIORDALISO, A. A hybrid sales forecasting system based on clustering and decision trees. **Decision Support Systems**, v. 42, n. 1, p. 408–421, out. 2006.

TRAPPEY, C. V.; WU, H.-Y. An evaluation of the time-varying extended logistic, simple logistic, and Gompertz models for forecasting short product lifecycles. **Advanced Engineering Informatics**, v. 22, n. 4, p. 421–430, out. 2008.

TRIVIÑOS, A. **Bases teórico-metodológicas preliminares da pesquisa qualitativa em ciências sociais**. Porto Alegre: Faculdade Ritter dos Reis, 2001.

WEI, S.; ZHANG, J.; LI, Z. **A supplier-selecting system using a neural network**IEEE international conference on intelligent processing systems. **Anais...**1997

WHANG, S. Markdown Competition. In: AGRAWAL, N.; SMITH, S. (Eds.). **Retail supply chain management**. New York: Springer Science + Business Media, 2009.

WOMACK, L.; JONES, D. **Lean Thinking**. New York: Simon and Schuster, 1996.

WONG, W. K.; GUO, Z. X. A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. **International Journal of Production Economics**, v. 128, n. 2, p. 614–624, dez. 2010.

WU, F.-S.; CHU, W.-L. Diffusion models of mobile telephony. **Journal of Business Research**, v. 63, n. 5, p. 497–501, maio 2010.

XIA, M. et al. Fashion retailing forecasting based on extreme learning machine with adaptive metrics of inputs. **Knowledge-Based Systems**, v. 36, p. 253–259, dez. 2012.

XIA, M.; WONG, W. K. A seasonal discrete grey forecasting model for fashion retailing. **Knowledge-Based Systems**, v. 57, p. 119–126, fev. 2014.

YANG, Y.; WILLIAMS, E. Logistic model-based forecast of sales and generation of obsolete computers in the U.S. **Technological Forecasting and Social Change**, v. 76, n. 8, p. 1105–1114, out. 2009.

YELLAND, P. M.; KIM, S.; STRATULATE, R. A Bayesian Model for Sales Forecasting at Sun Microsystems. **Interfaces**, v. 40, n. 2, p. 118–129, abr. 2010.

YIN, R. **Estudo de caso: planejamento e métodos**. Porto Alegre: Bookman, 2005.

YIN, Y. et al. A new fuzzy neural networks model for demand forecasting. **Automation and Logistics**, ..., n. September, p. 372–376, 2008.

ZOTTERI, G.; KALCHSCHMIDT, M.; CANIATO, F. The impact of aggregation level on forecasting performance. **International Journal of Production Economics**, v. 93-94, p. 479–491, jan. 2005.

APÊNDICE A

Sem.	Loja 4			Loja 6			Loja 7		
	2010	2011	2012	2010	2011	2012	2010	2011	2012
1	62	27	43	47	32	20	81	39	66
2	57	43	28	40	64	8	53	40	46
3	103	116	17	82	90	14	72	75	41
4	55	47	27	61	43	43	88	86	61
5	65	40	49	60	44	35	106	81	88
6	120	79	59	83	64	56	166	105	110
7	103	81	42	89	76	42	163	139	82
8	127	70	66	81	49	53	147	95	89
9	130	55	77	107	72	56	152	94	107
10	187	91	90	135	54	109	232	106	145
11	181	75	100	171	65	94	277	119	126
12	183	73	74	130	66	74	229	104	127
13	165	100	50	166	95	48	211	105	99
14	208	196	86	199	229	96	313	264	128
15	355	91	178	202	111	116	298	155	209
16	267	91	100	145	69	93	252	93	150
17	265	121	136	146	86	137	287	151	154
18	317	104	101	325	85	144	442	177	211
19	316	153	123	297	95	141	468	209	162
20	307	187	173	278	158	159	442	242	229
21	397	300	187	252	171	194	435	313	277
22	607	387	263	548	276	194	821	460	445
23	880	502	457	758	462	413	1247	718	685
24	1420	712	794	1153	638	709	1756	1054	1283
25	1694	1240	971	1249	995	916	2032	1585	1466
26	709	457	494	702	492	669	975	816	1209
TOTAL	11290	7449	6797	9516	6692	6645	13755	9436	9807

Dados de vendas por semana para o subgrupo de Rasteiras

Fonte: o autor (2014)

Sem.	Loja 4			Loja 6			Loja 7		
	2010	2011	2012	2010	2011	2012	2010	2011	2012
1	51	51	49	34	37	43	31	52	89
2	71	87	55	63	81	41	31	58	87
3	71	94	43	56	69	40	53	67	167
4	61	61	62	46	47	62	57	98	155
5	55	56	57	43	41	52	64	100	158
6	54	64	44	48	41	54	57	92	158

7	59	49	67	49	39	57	32	56	114
8	44	45	41	42	39	52	36	68	95
9	47	44	44	40	43	36	40	66	108
10	43	31	49	51	52	50	35	53	106
11	47	34	62	53	57	62	48	79	123
12	41	24	58	54	45	67	36	50	110
13	68	48	84	49	52	49	45	46	148
14	70	105	54	86	128	55	53	147	90
15	102	36	55	46	28	68	42	61	131
16	59	21	26	46	36	65	37	50	118
17	69	22	32	28	30	64	75	49	130
18	62	21	59	74	21	60	88	71	117
19	53	34	38	73	23	62	65	66	153
20	37	42	50	58	20	66	57	69	165
21	30	14	45	53	22	51	52	69	123
22	38	20	74	32	12	50	60	68	116
23	28	30	61	33	38	60	42	100	164
24	32	86	68	30	114	72	34	210	179
25	43	142	113	34	111	109	78	264	243
26	24	51	106	43	74	79	31	144	233
TOTAL	3369	3323	3508	3274	3311	3538	3289	4264	5592

Dados de vendas por semana para o subgrupo de Sapatilhas

Fonte: o autor (2014)

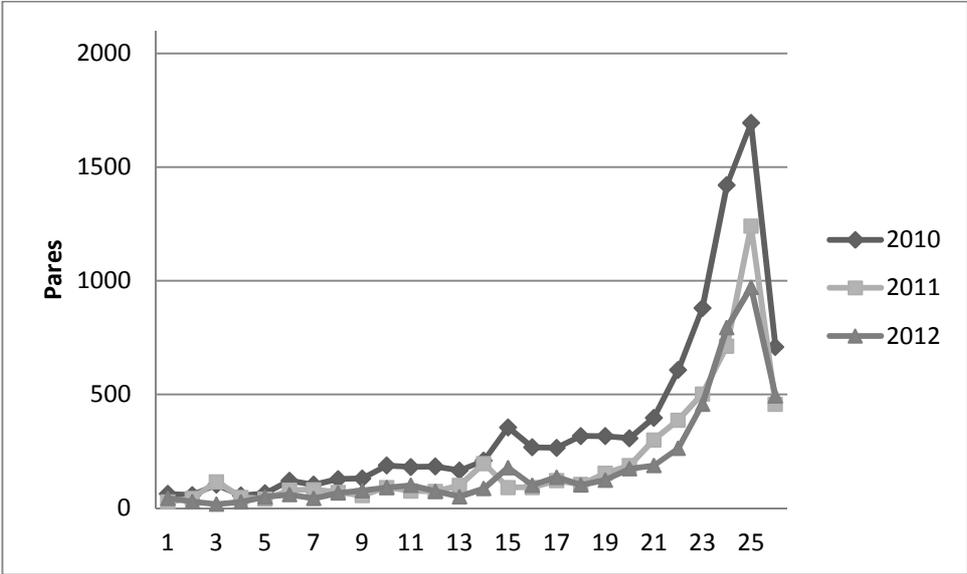
Sem.	Loja 4			Loja 6			Loja 7		
	2010	2011	2012	2010	2011	2012	2010	2011	2012
1	63	34	99	34	41	49	31	77	73
2	70	28	106	56	51	112	37	90	98
3	37	12	54	31	42	38	39	92	143
4	40	46	37	26	53	47	58	107	148
5	46	48	61	31	41	70	58	68	169
6	58	48	69	29	28	64	54	64	152
7	44	32	58	38	47	89	31	47	120
8	60	38	47	33	33	75	36	48	128
9	70	35	90	35	25	54	38	40	95
10	75	29	120	29	25	55	55	45	130
11	53	45	87	31	41	51	46	79	88
12	58	62	84	35	55	66	56	110	102
13	62	59	72	31	55	50	62	120	100
14	82	89	88	43	97	44	80	144	104
15	124	79	94	45	69	63	62	120	134
16	111	80	36	54	92	52	57	122	81
17	89	113	30	34	74	56	41	120	105

18	72	103	52	54	73	85	99	138	141
19	53	81	56	51	88	59	102	101	170
20	44	62	47	43	77	48	73	110	143
21	43	71	97	34	41	68	49	85	96
22	46	104	68	40	58	76	46	145	142
23	47	104	110	57	99	129	81	248	258
24	81	112	168	61	97	147	92	202	387
25	86	152	296	121	103	242	222	203	600
26	51	60	208	75	61	154	139	100	417
TOTAL	3675	3737	4346	3161	3577	4055	3754	4836	6336

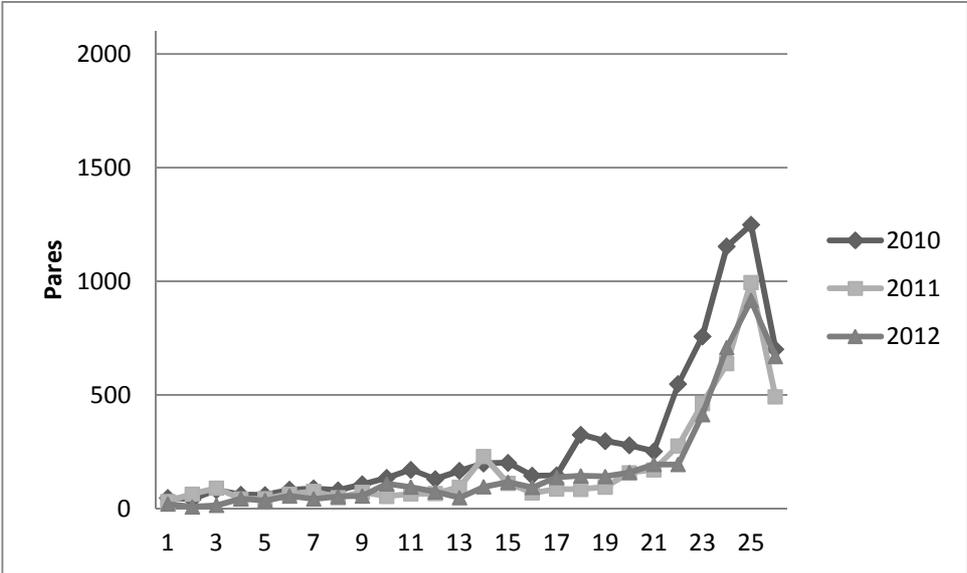
Dados de vendas por semana para o subgrupo de Sapatilhas de Tecido

Fonte: o autor (2014)

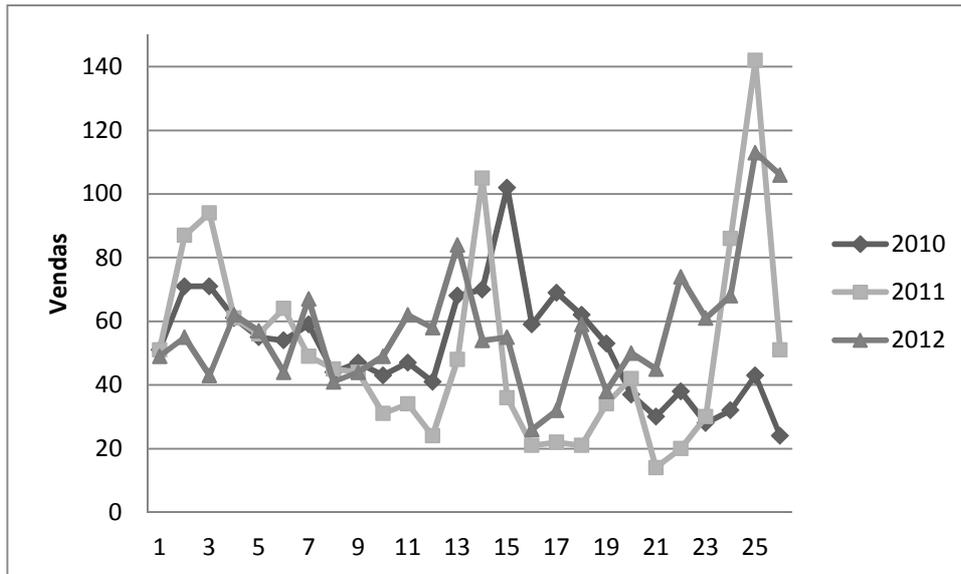
APÊNDICE B



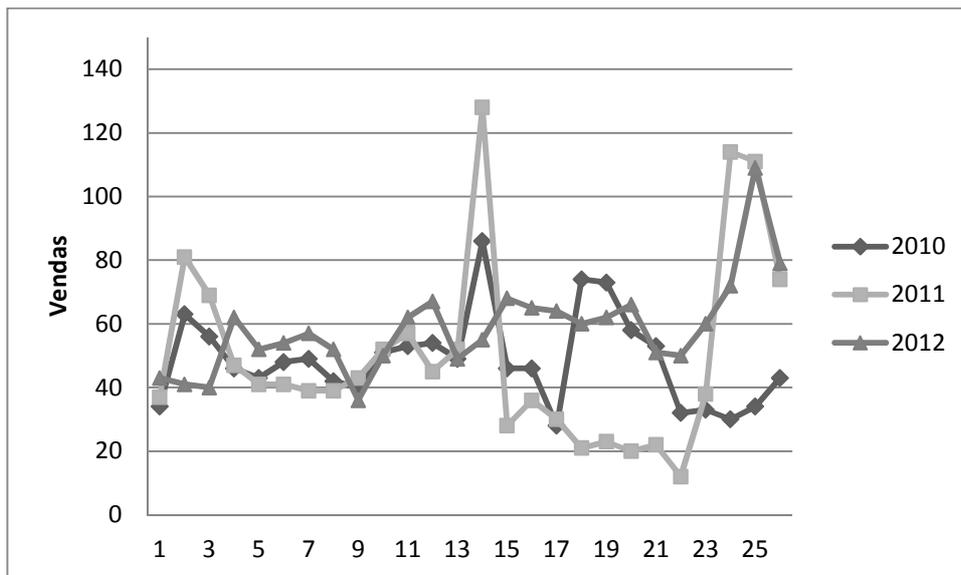
Vendas por semana para o subgrupo de Rasteiras – Loja 4
Fonte: o autor (2014)



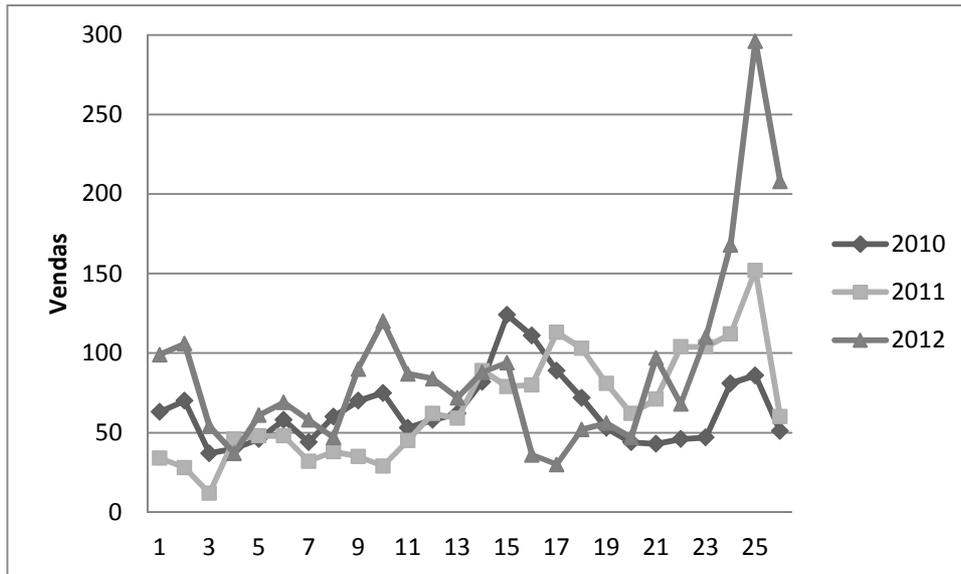
Vendas por semana para o subgrupo de Rasteiras – Loja 6
Fonte: o autor (2014)



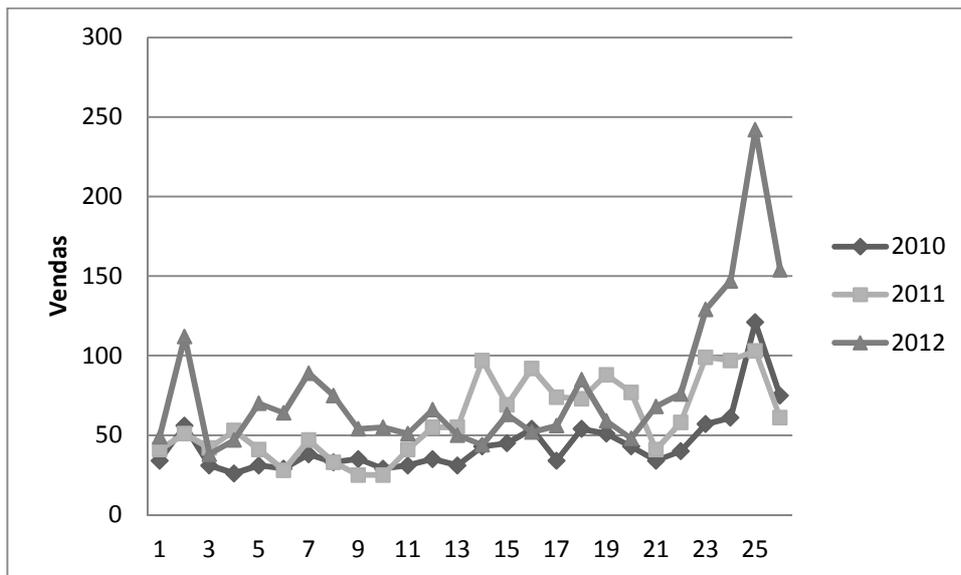
Vendas por semana para o subgrupo de Sapatilhas – Loja 4
Fonte: o autor (2014)



Vendas por semana para o subgrupo de Sapatilhas – Loja 6
Fonte: o autor (2014)



Vendas por semana para o subgrupo de Sapatilhas de Tecido – Loja 4
Fonte: o autor (2014)



Vendas por semana para o subgrupo de Sapatilhas de Tecido – Loja 6
Fonte: o autor (2014)

APÊNDICE C

Sem.	Loja 4					Loja 6					Loja 7				
	2010	2011	2012	2013*	2013	2010	2011	2012	2013*	2013	2010	2011	2012	2013*	2013
1	61	38	21	32	22	39	35	23	29	50	65	43	26	36	51
2	66	41	23	34	13	43	37	25	31	26	71	46	29	40	32
3	72	44	25	37	28	48	40	27	34	48	78	50	32	44	27
4	78	47	28	40	10	53	42	30	37	25	86	54	36	48	34
5	84	50	31	44	17	58	45	33	40	37	95	59	41	54	49
6	92	54	34	48	52	64	48	36	43	51	105	64	46	59	109
7	100	58	38	53	50	71	52	39	47	49	116	69	51	66	73
8	109	62	42	58	62	79	55	43	52	56	128	76	58	73	97
9	120	67	47	63	71	88	60	48	57	58	142	83	65	81	80
10	132	73	53	70	118	98	64	53	63	94	158	91	74	91	153
11	145	80	59	77	103	110	70	59	69	147	176	100	84	102	256
12	160	87	67	86	142	123	76	65	77	106	196	111	96	114	239
13	178	96	76	96	117	139	83	73	85	169	220	123	109	129	196
14	199	106	86	108	152	157	91	82	95	159	248	137	125	146	153
15	223	118	98	121	140	178	101	93	107	148	281	154	145	167	171
16	251	132	113	138	118	203	113	106	122	116	320	174	168	191	223
17	286	149	130	158	96	233	127	122	139	94	367	199	196	221	168
18	329	171	153	183	125	270	145	141	161	134	424	230	231	259	170
19	382	198	181	214	137	316	167	166	188	150	496	269	276	306	287
20	450	234	217	255	205	375	197	198	223	228	587	320	335	367	309
21	542	284	267	311	266	452	238	242	271	222	707	390	414	449	338
22	669	358	338	391	236	556	298	305	339	227	872	492	526	566	364
23	859	475	446	513	515	705	394	403	444	465	1109	653	696	742	626
24	1170	695	631	726	622	936	572	575	625	562	1482	942	981	1042	886
25	1775	1249	1018	1192	1038	1338	1016	951	1025	1033	2148	1620	1556	1659	1465
26	986	612	536	622	921	1046	675	661	720	837	1637	1081	1096	1169	1317
	9518	5574	4758	5671	5376	7778	4843	4598	5122	5291	12314	7630	7493	8221	7873

Previsões e realizado 2013 para subgrupo de Rasteiras

Fonte: o autor (2014)

Sem.	Loja 4					Loja 6					Loja 7				
	2010	2011	2012	2013*	2013	2010	2011	2012	2013*	2013	2010	2011	2012	2013*	2013
1	64	59	47	54	61	49	48	44	47	69	41	33	108	72	170
2	63	58	47	54	72	49	48	45	47	52	41	35	110	74	66
3	62	58	48	54	41	49	48	46	48	33	42	36	112	75	47
4	61	57	49	53	103	49	49	47	48	71	43	37	114	77	181
5	60	56	49	53	79	49	49	48	49	90	44	39	116	78	272
6	59	55	50	53	82	49	49	49	49	121	44	41	118	80	277
7	58	54	51	53	83	49	49	50	50	140	45	43	120	82	233
8	57	54	51	53	65	49	49	52	50	95	46	45	122	83	189
9	56	53	52	53	84	49	49	53	51	136	47	47	124	85	124

10	55	52	53	53	101	49	49	54	51	103	47	49	126	87	190
11	54	52	54	53	74	49	49	55	52	84	48	52	128	89	276
12	54	51	54	53	77	49	49	56	52	92	49	55	130	92	213
13	53	50	55	53	94	49	49	57	53	107	50	58	133	94	289
14	52	49	56	53	124	49	49	58	54	124	51	62	135	96	266
15	51	49	57	53	111	49	49	60	54	90	51	67	137	99	219
16	51	48	58	53	113	49	49	61	55	111	52	72	140	102	229
17	50	47	59	53	81	49	49	62	56	82	53	78	142	105	171
18	49	47	59	54	83	49	49	64	56	78	54	85	145	109	198
19	49	46	60	54	103	49	49	65	57	77	55	93	147	112	190
20	48	46	61	54	91	49	49	66	58	82	55	103	150	117	211
21	47	45	62	54	81	49	50	68	58	78	56	116	152	122	180
22	47	44	63	54	82	49	50	69	59	92	57	132	155	129	209
23	46	44	64	54	88	49	50	71	60	138	58	153	158	136	226
24	46	43	65	54	133	49	50	72	61	173	59	183	161	147	330
25	45	42	66	55	322	49	50	74	61	270	60	227	163	162	577
26	53	50	74	63	321	75	76	109	93	258	68	204	187	168	462
	1389	1310	1464	1403	2749	1296	1302	1556	1428	2846	1316	2144	3531	2672	5995

Previsões e realizado 2013 para subgrupo de Sapatilhas

Fonte: o autor (2014)

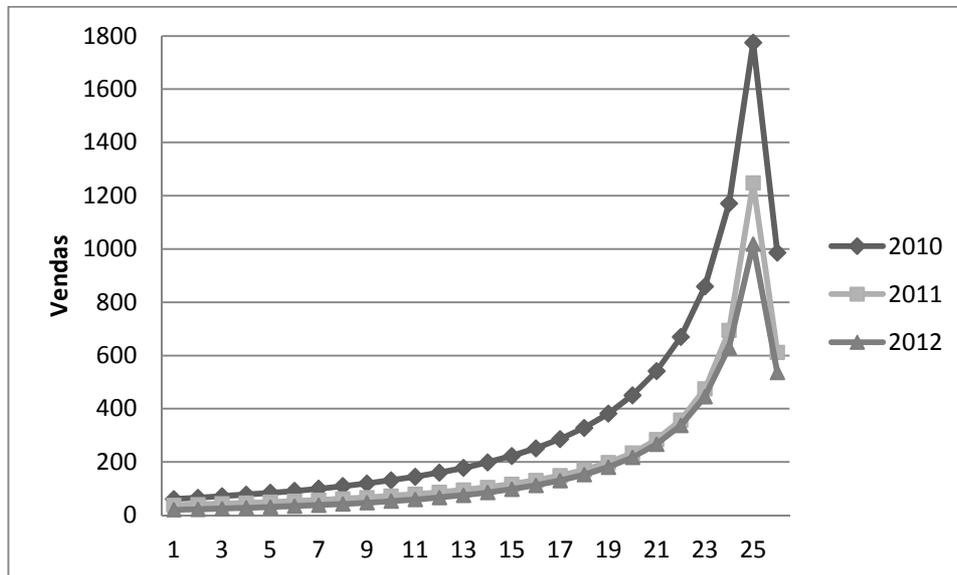
Sem.	Loja 4					Loja 6					Loja 7				
	2010	2011	2012	2013*	2013	2010	2011	2012	2013*	2013	2010	2011	2012	2013*	2013
1	48	28	31	33	52	24	36	30	31	52	29	62	49	50	48
2	51	30	32	34	83	25	37	32	32	71	30	64	51	52	42
3	53	32	33	36	46	26	39	33	33	57	31	66	53	54	11
4	56	34	34	37	36	27	40	34	35	24	33	68	55	56	107
5	58	37	36	39	33	28	42	35	36	29	34	70	58	58	99
6	59	39	38	41	54	29	43	37	38	36	35	72	61	60	117
7	61	42	39	43	33	30	45	39	39	40	37	75	64	63	63
8	63	44	41	45	40	31	47	40	41	31	38	78	67	66	67
9	64	47	43	47	34	32	49	42	43	62	40	81	71	69	102
10	65	50	46	50	43	33	51	45	45	49	42	84	75	73	130
11	66	53	48	52	36	34	53	47	47	36	44	88	79	77	78
12	67	57	51	55	22	36	55	50	49	29	47	92	85	81	81
13	67	61	54	58	29	37	57	53	52	40	49	96	91	86	107
14	68	65	58	61	43	39	59	56	55	44	52	100	97	92	115
15	68	69	63	65	86	41	62	60	58	52	55	105	105	98	105
16	69	73	68	69	95	43	65	65	62	85	59	111	115	106	161
17	69	78	73	74	55	45	67	70	66	53	64	117	126	115	98
18	70	83	80	79	48	48	70	76	70	29	69	124	140	125	91
19	70	88	89	86	42	51	73	83	76	36	75	132	157	138	79
20	70	94	99	93	26	54	77	92	82	55	82	141	179	154	71
21	70	99	112	103	55	58	80	103	90	91	90	152	208	175	150
22	70	106	130	114	100	62	84	118	100	84	101	164	248	203	186

23	71	112	153	130	154	67	88	136	112	167	114	178	307	243	332
24	71	119	187	151	210	73	92	162	129	184	131	194	404	305	302
25	71	127	240	183	179	80	96	199	153	190	155	214	590	421	338
26	77	127	194	158	141	86	110	187	151	175	162	243	502	379	307
	1691	1795	2073	1939	1775	1140	1614	1924	1724	1801	1698	2969	4036	3398	3387

Previsões e realizado 2013 para subgrupo de Sapatilhas de Tecido

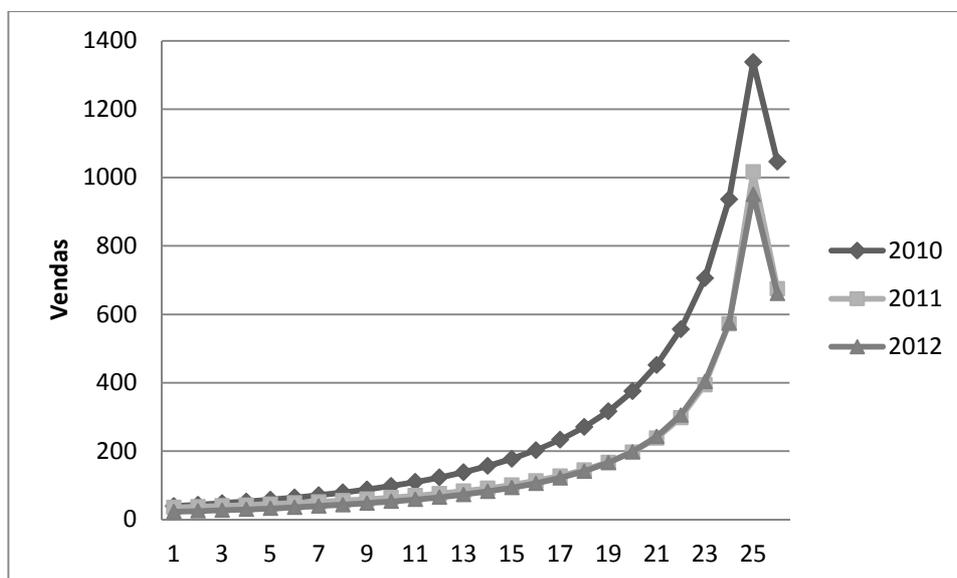
Fonte: o autor (2014)

APÊNDICE D



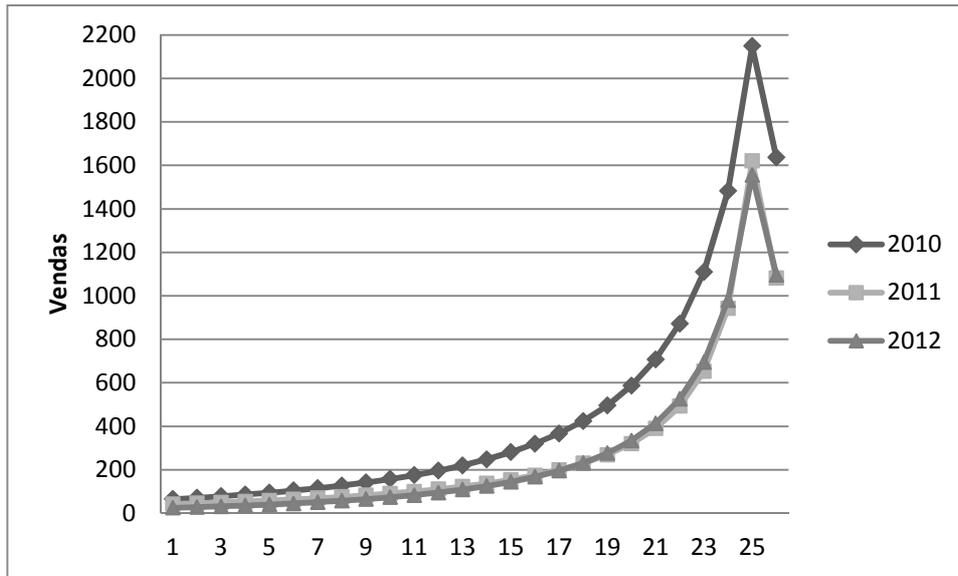
Modelos Logísticos para subgrupo de Rasteiras – Loja 4

Fonte: o autor (2014)

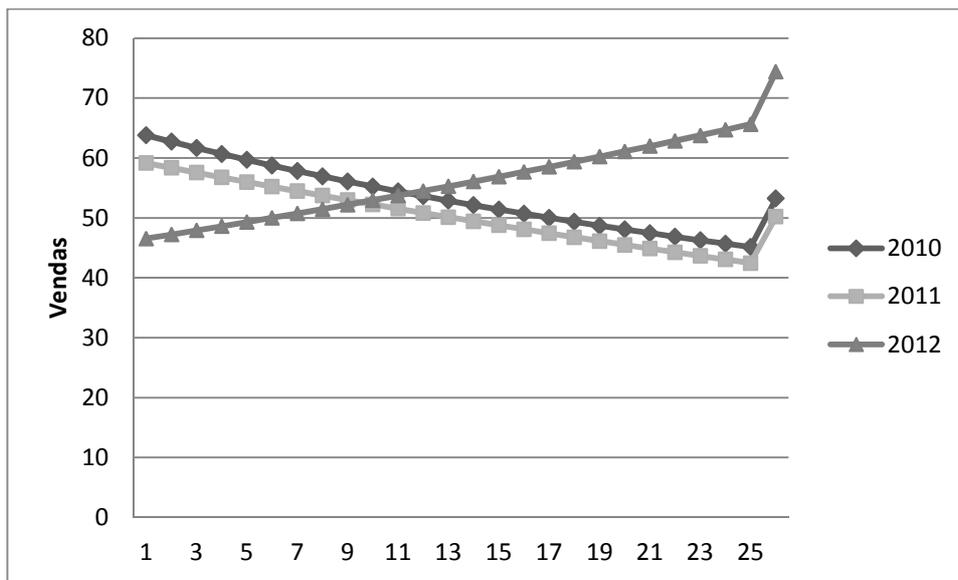


Modelos Logísticos para subgrupo de Rasteiras – Loja 6

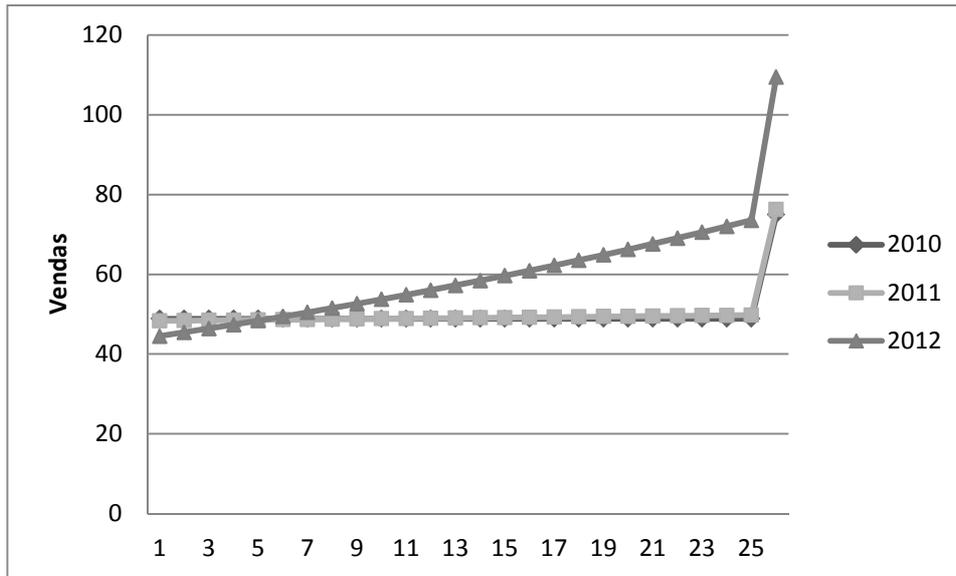
Fonte: o autor (2014)



Modelos Logísticos para subgrupo de Rasteiras – Loja 7
Fonte: o autor (2014)

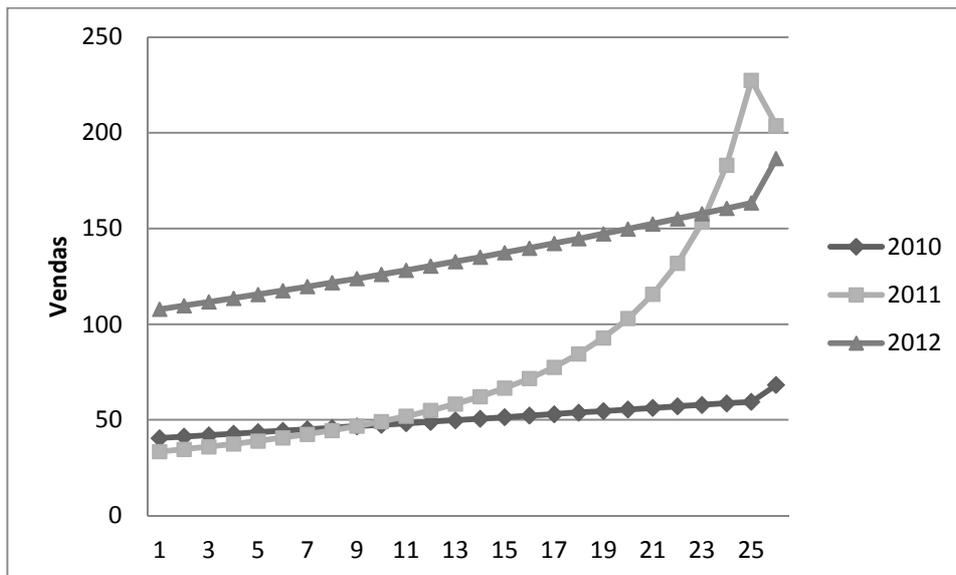


Modelos Logísticos para subgrupo de Sapatilhas – Loja 4
Fonte: o autor (2014)



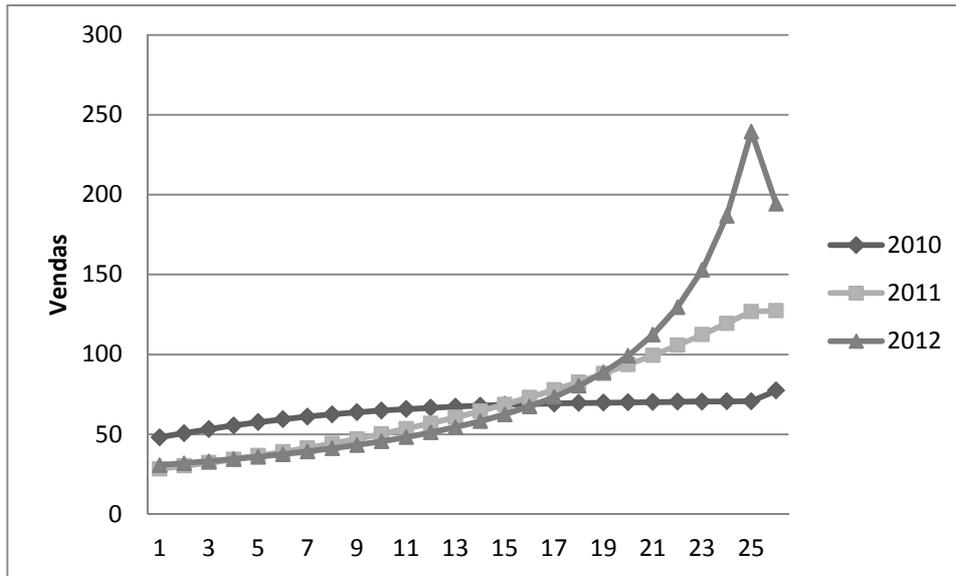
Modelos Logísticos para subgrupo de Sapatilhas – Loja 6

Fonte: o autor (2014)



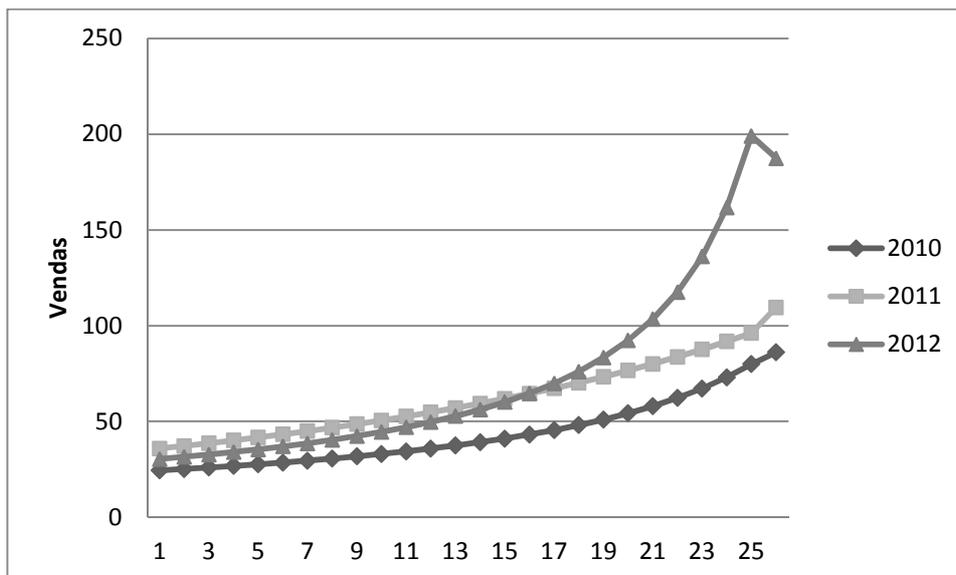
Modelos Logísticos para subgrupo de Sapatilhas – Loja 7

Fonte: o autor (2014)



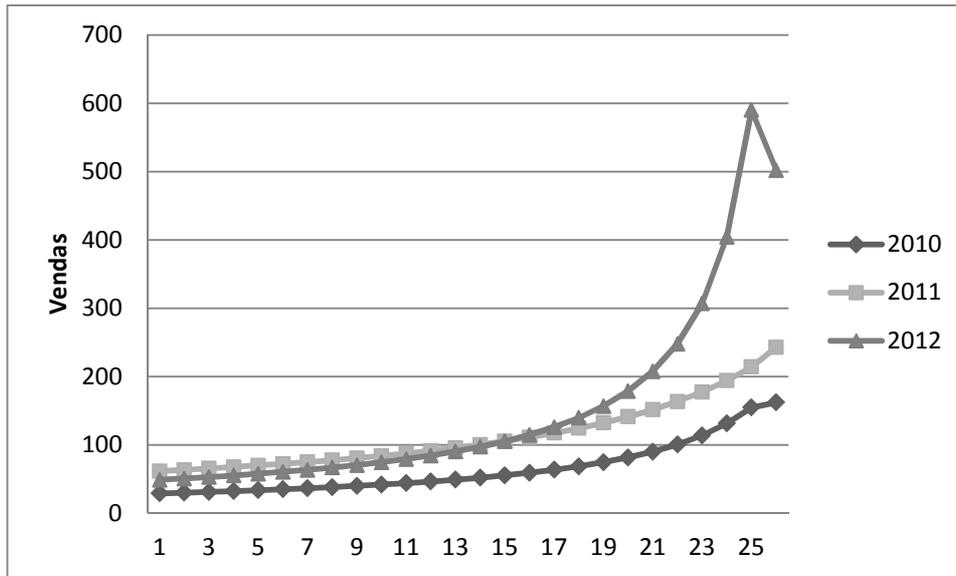
Modelos Logísticos para subgrupo de Sapatilhas de Tecido – Loja 4

Fonte: o autor (2014)



Modelos Logísticos para subgrupo de Sapatilhas de Tecido – Loja 6

Fonte: o autor (2014)



Modelos Logísticos para subgrupo de Sapatilhas de Tecido – Loja 7

Fonte: o autor (2014)

APÊNDICE E

MODELO	10	11	12	13	14	15	16	17
RT 0161 - FERRUGEM	5	8	6	6	0	0	0	1
MODELO		4	4	4	4	2	6	0
ORIGINAL	5	5	5	5	5	4	0	0
RT 0161 - PRETO	8	5	9	5	0	0	0	0
MODELO		7	6	2	6	0	0	0
ORIGINAL	5	5	5	5	5	4	0	0
RT 0161 - ROYAL	3	2	6	2	0	4	1	2
MODELO		3	3	3	3	5	2	2
ORIGINAL	5	5	5	5	5	3	0	0
RT 0158 - AREIA	2	6	11	2	2	1	1	0
MODELO		4	4	4	4	6	6	0
ORIGINAL	5	5	5	5	5	5	0	0
RT 0158 - PRETO	8	15	8	7	3	1	0	0
MODELO		7	6	7	7	9	0	0
ORIGINAL	8	8	8	8	7	5	0	0
RT 0158 - ROYAL	1	6	4	1	1	2	0	0
MODELO		3	3	3	1	1	1	0
ORIGINAL	5	5	5	5	5	3	0	0

Previsão de vendas para a semana 10 – Loja 7

Fonte: o autor (2014)

MODELO	14	15	16	17	18	19	20	21
RT 0173 - ACQUA	1	0	1	2	0	0	0	0
MODELO		2	2	2	2	2	2	2
ORIGINAL	7	7	7	7	7	7	0	0
RT 0173 - AREIA	3	3	2	2	2	0	0	0
MODELO		5	6	5	5	5	5	5
ORIGINAL	8	8	8	8	8	8	0	0
RT 0173 - MARINHO	2	2	2	0	1	3	1	0
MODELO		4	4	4	3	4	4	4
ORIGINAL	8	8	8	8	8	8	0	0
RT 0173 - MELANCIA	0	3	1	1	2	0	0	1

MODELO		1	1	1	1	1	1	1
ORIGINAL	7	7	7	7	7	7	0	0

Previsão de vendas para a semana 14 – Loja 7

Fonte: o autor (2014)

MODELO	19	20	21	22	23	24	25	26
RT 0176 - CAFÉ	2	5	6	8	9	19	4	0
MODELO		3	4	4	4	6	8	8
ORIGINAL	9	9	9	9	9	8	0	0
RT 0176 - CHICLETE	1	1	1	1	8	9	18	8
MODELO		2	2	2	3	3	4	4
ORIGINAL	9	9	9	9	9	8	0	0
RT 0176 - PRETO	2	17	14	3	12	5	2	1
MODELO		3	4	4	4	6	8	8
ORIGINAL	10	10	10	10	9	7	0	0
RT 0176 - ROSA	5	9	10	8	10	8	6	2
MODELO		7	8	9	10	13	6	0
ORIGINAL	10	10	10	10	10	8	0	0
RT 0176 - ROYAL	4	5	8	3	18	5	9	2
MODELO		6	7	7	8	11	11	0
ORIGINAL	9	9	9	9	9	9	0	0
RT 0176 - VERDE	1	9	6	1	5	13	15	5
MODELO		2	2	2	3	3	4	4
ORIGINAL	10	10	10	10	9	6	0	0
RT 0176 - VIOLETA	0	0	2	1	4	1	8	13
MODELO		1	1	1	1	1	1	1
ORIGINAL	9	9	9	9	9	8	0	0
RT 0181 - BRONZE	11	18	0	2	1	0	0	0
MODELO		14	7	0	0	0	0	0
ORIGINAL	6	6	6	6	5	3	0	0
RT 0181 - OURO	21	9	1	0	1	0	0	0
MODELO		11	0	0	0	0	0	0
ORIGINAL	6	6	6	6	5	3	0	0
RT 0181 - PRETO	24	6	0	1	0	0	0	0
MODELO		7	0	0	0	0	0	0
ORIGINAL	6	6	6	6	5	3	0	0

RT 0191 - BRANCO	4	3	6	3	11	4	0	3
MODELO		5	6	7	10	2	0	0
ORIGINAL	6	6	6	6	5	5	0	0
RT 0191 - FERRUGEM	7	3	1	5	8	19	3	4
MODELO		9	11	11	12	0	0	0
ORIGINAL	9	9	9	9	8	6	0	0
RT 0191 - PRETO	11	5	5	12	7	11	0	5
MODELO		14	16	15	0	0	0	0
ORIGINAL	10	10	10	10	10	6	0	0
RT 0194 - ACQUA	2	0	2	3	1	6	5	0
MODELO		3	3	4	4	5	9	7
ORIGINAL	7	7	7	7	7	5	0	0
RT 0194 - AMARELO	1	1	0	3	3	5	14	1
MODELO		2	2	2	2	3	4	3
ORIGINAL	7	7	7	7	7	5	0	0
RT 0194 - BRONZE	5	3	5	3	2	3	1	1
MODELO		7	8	8	4	0	0	0
ORIGINAL	7	7	7	7	7	5	0	0
RT 0194 - CENOURA	1	0	1	0	6	8	6	2
MODELO		2	2	2	2	3	4	3
ORIGINAL	7	7	7	7	7	5	0	0
RT 0194 - FERRUGEM	1	1	2	8	3	11	6	4
MODELO		2	2	2	2	3	4	3
ORIGINAL	7	7	7	7	7	5	0	0
RT 0194 - MARINHO	0	2	0	3	1	15	2	1
MODELO		1	1	1	1	1	1	1
ORIGINAL	7	7	7	7	7	5	0	0
RT 0194 - OURO	0	0	5	7	8	20	19	6
MODELO		1	1	1	1	1	1	1
ORIGINAL	14	14	14	14	14	10	0	0
RT 0194 - PRATA VELHO	1	2	0	0	0	7	10	2
MODELO		2	2	2	3	3	4	3
ORIGINAL	9	9	9	9	9	7	0	0

RT 0194 - PRETO	2	5	4	3	7	4	12	3
MODELO		3	3	4	4	5	9	7
ORIGINAL	7	7	7	7	7	5	0	0
RT 0194 - ROSE GOLD	1	1	1	2	8	9	2	1
MODELO		2	2	2	2	3	4	3
ORIGINAL	6	6	6	6	5	3	0	0
RT 0194 - VIOLETA	0	0	1	1	0	3	6	1
MODELO		1	1	1	1	1	1	1
ORIGINAL	6	6	6	6	5	3	0	0
RT 0197 - ACQUA	1	2	1	1	3	6	8	7
MODELO		2	2	2	2	3	4	3
ORIGINAL	6	6	6	6	5	3	0	0
RT 0197 - CENOURA	1	4	2	2	10	8	6	7
MODELO		2	2	2	2	3	4	3
ORIGINAL	7	7	7	7	7	5	0	0
RT 0197 - ROYAL	1	0	2	1	1	8	5	8
MODELO		2	2	2	2	3	4	3
ORIGINAL	6	6	6	6	5	3	0	0

Previsão de vendas para a semana 19 – Loja 7

Fonte: o autor (2014)

MODELO	21	22	23	24	25	26
RT 0193 - CAFÉ	2	0	6	1	12	5
MODELO		4	4	6	8	6
ORIGINAL	10	10	10	10	10	8
RT 0193 - ROYAL	0	1	6	3	2	1
MODELO		1	1	1	1	1
ORIGINAL	10	10	10	10	10	8

Previsão de vendas para a semana 21 – Loja 7

Fonte: o autor (2014)

APÊNDICE F

SEM.	MODELO			6 SEM.	8 SEM.
5	RT 0141 - PRETO	MODELO	APE	7,692	0,000
			MAPE*	53,846	50,000
		ORIGINAL	APE	53,846	25,000
			MAPE*	53,846	62,500
5	RT 0141 - VIOLETA	MODELO	APE	300,000	180,000
			MAPE*	300,000	220,000
		ORIGINAL	APE	500,000	260,000
			MAPE*	500,000	340,000
5	RT 0141 - CENOURA	MODELO	APE	11,111	16,667
			MAPE*	77,778	83,333
		ORIGINAL	APE	111,111	58,333
			MAPE*	133,333	125,000
5	RT 0141 - FERRUGEM	MODELO	APE	9,091	12,500
			MAPE*	45,455	37,500
		ORIGINAL	APE	100,000	37,500
			MAPE*	100,000	100,000
5	RT 0150 - CARAMELO	MODELO	APE	150,000	87,500
			MAPE*	150,000	87,500
		ORIGINAL	APE	625,000	262,500
			MAPE*	625,000	362,500
5	RT 0150 - CENOURA	MODELO	APE	28,571	22,222
			MAPE*	57,143	66,667
		ORIGINAL	APE	185,714	122,222
			MAPE*	185,714	166,667
5	RT 0150 - AMARELO	MODELO	APE	100,000	100,000
			MAPE*	100,000	100,000
		ORIGINAL	APE	400,000	233,333
			MAPE*	400,000	300,000
5	RT 0150 - MARINHO	MODELO	APE	400,000	0,000
			MAPE*	400,000	114,286
		ORIGINAL	APE	2500,000	271,429
			MAPE*	2500,000	442,857
5	RT 0155 - CAFÉ	MODELO	APE	78,261	72,414
			MAPE*	78,261	79,310
		ORIGINAL	APE	13,043	10,345
			MAPE*	39,130	51,724
5	RT 0155 - MARINHO	MODELO	APE	0,000	56,250

			MAPE*	40,000	68,750
		ORIGINAL	APE	400,000	56,250
			MAPE*	400,000	193,750
5	RT 0155 - OURO	MODELO	APE	74,074	66,667
			MAPE*	74,074	72,727
		ORIGINAL	APE	11,111	9,091
			MAPE*	70,370	75,758
10	RT 0161 - FERRUGEM	MODELO	APE	10,000	14,286
			MAPE*	70,000	100,000
		ORIGINAL	APE	20,000	14,286
			MAPE*	70,000	71,429
10	RT 0161 - PRETO	MODELO	APE	10,526	10,526
			MAPE*	73,684	73,684
		ORIGINAL	APE	26,316	26,316
			MAPE*	68,421	68,421
10	RT 0161 - ROYAL	MODELO	APE	21,429	23,529
			MAPE*	64,286	58,824
		ORIGINAL	APE	64,286	35,294
			MAPE*	92,857	94,118
10	RT 0158 - AREIA	MODELO	APE	0,000	21,739
			MAPE*	81,818	100,000
		ORIGINAL	APE	13,636	8,696
			MAPE*	77,273	78,261
10	RT 0158 - PRETO	MODELO	APE	5,882	5,882
			MAPE*	64,706	64,706
		ORIGINAL	APE	5,882	5,882
			MAPE*	47,059	47,059
10	RT 0158 - ROYAL	MODELO	APE	21,429	14,286
			MAPE*	50,000	57,143
		ORIGINAL	APE	7,143	7,143
			MAPE*	64,286	64,286
14	RT 0173 - ACQUA	MODELO	APE	233,333	366,667
			MAPE*	233,333	366,667
		ORIGINAL	APE	1066,667	1066,667
			MAPE*	1066,667	1066,667
14	RT 0173 - AREIA	MODELO	APE	188,889	300,000
			MAPE*	188,889	300,000
		ORIGINAL	APE	344,444	344,444
			MAPE*	344,444	344,444
14	RT 0173 - MARINHO	MODELO	APE	137,500	200,000

			MAPE*	137,500	200,000
		ORIGINAL	APE	400,000	344,444
			MAPE*	400,000	366,667
14	RT 0173 - MELANCIA	MODELO	APE	28,571	12,500
			MAPE*	57,143	62,500
		ORIGINAL	APE	400,000	337,500
			MAPE*	400,000	362,500
19	RT 0176 - CAFÉ	MODELO	APE	55,319	27,451
			MAPE*	55,319	74,510
		ORIGINAL	APE	6,383	13,725
			MAPE*	40,426	45,098
19	RT 0176 - CHICLETE	MODELO	APE	40,000	56,522
			MAPE*	70,000	69,565
		ORIGINAL	APE	120,000	4,348
			MAPE*	130,000	113,043
19	RT 0176 - PRETO	MODELO	APE	58,824	31,481
			MAPE*	66,667	87,037
		ORIGINAL	APE	9,804	14,815
			MAPE*	45,098	48,148
19	RT 0176 - ROSA	MODELO	APE	4,444	0,000
			MAPE*	22,222	22,642
		ORIGINAL	APE	6,667	9,434
			MAPE*	6,667	20,755
19	RT 0176 - ROYAL	MODELO	APE	0,000	0,000
			MAPE*	56,410	52,000
		ORIGINAL	APE	15,385	10,000
			MAPE*	61,538	70,000
19	RT 0176 - VERDE	MODELO	APE	64,706	62,963
			MAPE*	70,588	66,667
		ORIGINAL	APE	32,353	16,667
			MAPE*	73,529	83,333
19	RT 0176 - VIOLETA	MODELO	APE	37,500	75,862
			MAPE*	62,500	82,759
		ORIGINAL	APE	450,000	51,724
			MAPE*	450,000	196,552
19	RT 0181 - BRONZE	MODELO	APE	0,000	0,000
			MAPE*	66,667	66,667
		ORIGINAL	APE	23,810	23,810
			MAPE*	138,095	138,095
19	RT 0181 - OURO	MODELO	APE	0,000	0,000

			MAPE*	36,364	36,364
		ORIGINAL	APE	136,364	136,364
			MAPE*	190,909	190,909
19	RT 0181 - PRETO	MODELO	APE	0,000	0,000
			MAPE*	28,571	28,571
		ORIGINAL	APE	136,36	136,36
			MAPE*	271,429	271,429
19	RT 0191 - BRANCO	MODELO	APE	11,111	0,000
			MAPE*	33,333	40,000
		ORIGINAL	APE	3,704	6,667
			MAPE*	48,148	53,333
19	RT 0191 - FERRUGEM	MODELO	APE	19,444	0,000
			MAPE*	125,000	120,930
		ORIGINAL	APE	13,889	4,651
			MAPE*	86,111	88,372
19	RT 0191 - PRETO	MODELO	APE	12,500	0,000
			MAPE*	102,500	102,222
		ORIGINAL	APE	15,000	2,222
			MAPE*	50,000	55,556
19	RT 0194 - ACQUA	MODELO	APE	58,333	105,882
			MAPE*	75,000	117,647
		ORIGINAL	APE	175,000	94,118
			MAPE*	191,667	164,706
19	RT 0194 - AMARELO	MODELO	APE	8,333	33,333
			MAPE*	58,333	70,370
		ORIGINAL	APE	175,000	22,222
			MAPE*	175,000	133,333
19	RT 0194 - BRONZE	MODELO	APE	68,750	50,000
			MAPE*	106,250	105,556
		ORIGINAL	APE	106,250	83,333
			MAPE*	106,250	105,556
19	RT 0194 - CENOURA	MODELO	APE	26,667	21,739
			MAPE*	93,333	73,913
		ORIGINAL	APE	120,000	43,478
			MAPE*	160,000	139,130
19	RT 0194 - FERRUGEM	MODELO	APE	56,000	48,571
			MAPE*	64,000	54,286
		ORIGINAL	APE	32,000	5,714
			MAPE*	88,000	91,429
19	RT 0194 - MARINHO	MODELO	APE	76,190	70,833

			MAPE*	85,714	79,167
		ORIGINAL	APE	57,143	37,500
			MAPE*	152,381	145,833
19	RT 0194 - OURO	MODELO	APE	87,500	89,231
			MAPE*	92,500	92,308
		ORIGINAL	APE	65,000	1,538
			MAPE*	115,000	109,231
19	RT 0194 - PRATA VELHO	MODELO	APE	33,333	9,524
			MAPE*	122,222	85,714
		ORIGINAL	APE	377,778	104,762
			MAPE*	377,778	219,048
19	RT 0194 - PRETO	MODELO	APE	17,391	7,895
			MAPE*	34,783	39,474
		ORIGINAL	APE	43,478	13,158
			MAPE*	43,478	65,789
19	RT 0194 - ROSE GOLD	MODELO	APE	47,619	25,000
			MAPE*	66,667	75,000
		ORIGINAL	APE	23,810	8,333
			MAPE*	109,524	108,333
19	RT 0194 - VIOLETA	MODELO	APE	0,000	41,667
			MAPE*	80,000	75,000
		ORIGINAL	APE	420,000	116,667
			MAPE*	420,000	233,333
19	RT 0197 - ACQUA	MODELO	APE	15,385	35,714
			MAPE*	46,154	50,000
		ORIGINAL	APE	100,000	7,143
			MAPE*	146,154	121,429
19	RT 0197 - CENOURA	MODELO	APE	57,692	53,846
			MAPE*	57,692	53,846
		ORIGINAL	APE	26,923	15,385
			MAPE*	73,077	82,051
19	RT 0197 - ROYAL	MODELO	APE	8,333	28,000
			MAPE*	75,000	60,000
		ORIGINAL	APE	116,667	4,000
			MAPE*	200,000	148,000
21	RT 0193 - CAFÉ	MODELO	APE	16,667	-
			MAPE*	66,667	-
		ORIGINAL	APE	100,000	-
			MAPE*	116,667	-
21	RT 0193 - ROYAL	MODELO	APE	61,538	-

	MAPE*	61,538	-
ORIGINAL	APE	269,231	-
	MAPE*	269,231	-

Medidas de desempenho preditivo para o modelo de curto prazo

Fonte: o autor (2014)