



UNIVERSIDADE FEDERAL DO PARANÁ

VICTOR POLLI FIDELIS

PREVISÃO DE DEMANDA NO AUXÍLIO DE ORDENS DE ABASTECIMENTO PARA
UM FORNECEDOR QUE GERENCIA ESTOQUES DE SEUS CLIENTES NO RAMO
PETROLÍFERO

CURITIBA

2019

VICTOR POLLI FIDELIS

PREVISÃO DE DEMANDA NO AUXÍLIO DE ORDENS DE ABASTECIMENTO PARA
UM FORNECEDOR QUE GERENCIA ESTOQUES DE SEUS CLIENTES NO RAMO
PETROLÍFERO

Trabalho de conclusão de curso apresentado ao curso de Graduação em Engenharia de Produção, Setor de Tecnologia da Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Engenharia de Produção.

Orientadora: Prof. Dr^a. Mariana Kleina

CURITIBA

2019

Dedico este trabalho a todos e todas que encontraram na Universidade Federal do Paraná uma oportunidade de melhoria de vida, bem como àqueles que reconhecem sua contribuição para o desenvolvimento social e econômico do nosso país.

AGRADECIMENTOS

Agradeço o professor orientador Prof. Dr. Guilherme Batista, por toda a sua contribuição durante a primeira parte deste trabalho.

A minha namorada Aline, sempre presente e muito paciente neste momento de conclusão de curso que ambos enfrentamos juntamente.

A empresa que disponibilizou os dados de demanda para a realização deste trabalho, sem os quais tal estudo não seria possível.

"Simplicidade é o objetivo final"
(CHOPIN)

RESUMO

A constante busca pela eficiência no fornecimento e a evolução dos sistemas informatizados leva diversas empresas a buscar parcerias para benefício mútuo em um cenário que se mostra cada vez mais competitivo. Dentre os modelos de parceria possibilitados pela evolução das tecnologias de *Eletronic Data Interchange*, foi feita uma revisão bibliográfica da cadeia de distribuição gerida tradicionalmente, planejamento, previsão e abastecimento colaborativo, programa de abastecimento contínuo e o inventário gerenciado pelo fornecedor. Com enfoque neste último, sendo listadas suas vantagens e desvantagens do ponto de vista do fornecedor e do fornecido. Foi feito um estudo de caso onde dados de demanda de produtos químicos derivados do petróleo de uma empresa abastecida em acordo de VMI foram analisados, nos quais foram aplicados métodos de previsão de demanda para auxílio na tomada de decisões logísticas de abastecimento. Foi constatado que, para a série de dados de demanda estudada, a utilização de redes neurais artificiais foi o método testado que demonstrou o menor erro médio quadrático para previsão de valores futuros de consumo do produto estudado.

Palavras-chave: VMI, Previsão de demanda, Séries temporais, Fornecimento de produtos líquidos, Indústria petroquímica.

ABSTRACT

The constant search for supply efficiency and the evolution of informatized systems has led several companies to seek partnerships for mutual benefit in a scenario that is increasingly competitive. Among the models of partnership made possible by the evolution of Electronic Data Interchange technologies, a bibliographic review of the Traditionally Managed Supply Chain, Collaborative Planning, Forecasting and Replenishment, Continuous Replenishment Program and the Vendor Managed Inventory was conducted, with a focus on the latter, with its advantages and disadvantages being listed from the vendor and supplier's point of view. A case study was carried out in which demand data of a petrochemical product from a company supplied under an VMI agreement was analyzed, in which demand forecasting methodologies were applied to assist in the decision making of supply logistics. It was found that, for the series of demand data studied, the utilization of artificial neural networks was the tested method that demonstrated the lowest Mean Square Error to predict future values of consumption of the studied material.

Keywords: VMI, Forecasting, Temporal series, Liquids Supply, Petrochemical industry.

LISTA DE FIGURAS

FIGURA 1 - O efeito chicote.....	29
FIGURA 2 – Exemplo de rede de camada única	40
FIGURA 3 – Exemplo de rede de múltipla camada.....	40
FIGURA 4 – Consumo Médio por Dia da Semana.....	45

LISTA DE TABELAS

TABELA 1 – Erro Médio Quadrático das Metodologias.....	50
--	----

LISTA DE ABREVIATURAS OU SIGLAS

CAPES/MEC - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Ministério da Educação

CPFR - *Collaborative Planning, Forecasting and Replenishment*, planejamento, previsão e abastecimento colaborativo.

CRP - *Continuous Replenishment Program*, programa de abastecimento contínuo

MAPE - *Mean Absolute Percentage Error*, erro percentual absoluto médio

MLP – *Multi Layer Perceptron*

MMQ - Método dos Mínimos Quadrados

MRP - *Material Resource Planner*, planejamento das necessidades de materiais

MSE - *Mean Square Error*, erro quadrático médio

RAE - *Relative Absolute Error*, erro relativo absoluto

RNA – Redes Neurais Artificiais

TSS - *Traditionally Managed Supply Chain*, cadeia de suprimento gerenciada tradicionalmente

VMI - *Vendor Managed Inventory*, inventário gerenciado pelo fornecedor

WMS - *Warehouse Management System*, sistema de gerenciamento de armazém

SUMÁRIO

1 INTRODUÇÃO	16
1.1 OBJETIVOS	17
1.1.1 Objetivo Geral	17
1.1.2 Objetivo Específico.....	17
1.2 CONTRIBUIÇÕES E LIMITAÇÕES	18
1.3 ESTRUTURA DO TRABALHO.....	19
2 REVISÃO DE LITERATURA	21
2.1 MODELOS DE FORNECIMENTO	22
2.1.1 Traditionally Managed Supply Chain (TSS).....	23
2.1.2 Collaborative Planning, Forecasting and Replenishment (CPFR)	24
2.1.3 Continuous Replenishment Program (CRP).....	25
2.1.4 Vendor Managed Inventory (VMI)	26
2.1.5 O Efeito Chicote	28
2.2 VANTAGENS E DESVANTAGENS DA UTILIZAÇÃO DO VMI.....	30
2.2.1 Vantagens Observadas pelo Fornecedor	30
2.2.2 Desvantagens Observadas pelo Fornecedor	31
2.2.3 Vantagens Observadas pelo Cliente	32
2.2.4 Desvantagens Observadas pelo Cliente	33
2.3 PREVISÃO DE DEMANDA	34
2.3.1 Médias Móveis	35
2.3.2 Decomposição Clássica da Série de Tempo (MMQ).....	36
2.3.3 Amortização Exponencial Simples	37
2.3.4 Amortização Exponencial Tripla – Holt Winters.....	38
2.3.5 Redes Neurais.....	40
2.3.6 Outliers	43
2.3.7 Avaliação dos métodos	44
2.3.7.1 MAPE	44
2.3.7.2 RAE.....	45
2.3.7.3 MSE.....	45
3 MATERIAL E MÉTODOS	46
3.1 ANÁLISE PRELIMINAR	46
3.2 APLICAÇÃO DE MÉTODOS DE PREVISÃO.....	48

4 APRESENTAÇÃO DOS RESULTADOS	50
5 CONSIDERAÇÕES FINAIS	52
6 REFERÊNCIAS	53
7 APÊNDICE – RESULTADOS DAS PREVISÕES PARA OS ÚLTIMOS 15 DIAS .	56
7.1 VALORES OBSERVADOS	56
7.2 AMORTIZAÇÃO EXPONENCIAL SEM SAZONALIDADE	57
7.3 AMORTIZAÇÃO EXPONENCIAL COM SAZONALIDADE.....	58
7.4 MÉDIAS MÓVEIS:.....	59
7.5 DECOMPOSIÇÃO CLÁSSICA DA SÉRIE TEMPORAL:.....	60
7.6 HOLT-WINTERS:	61
7.7 REDES NEURAIS	62
7.7.1 CÓDIGO UTILIZADO	62
7.7.2 Erro obtido em cada combinação de n e k	63
7.7.3 Erro obtido na previsão	65
7.8 DADOS DE DEMANDA.....	66

1 INTRODUÇÃO

O cenário do mercado atual fez com que produtos muitas vezes não sejam mais considerados portadores de diferenciais competitivos. Surge então a necessidade de se destacar inserindo valor no nível de serviço percebido com respostas eficientes às expectativas dos clientes. Como destacado por Mentzer et al. (2001), oferecer seus produtos de forma mais rápida e confiável que seu competidor não está mais sendo um diferencial, mas sim uma necessidade para se manter no mercado. Neste contexto e levando em conta o nível de concorrência, os estudos de modelos de abastecimento se tornam ainda mais relevantes quando se trata de sobrevivência no mercado, a ponto de serem considerados uma necessidade estratégica para organizações que agregam serviços logísticos em seu cotidiano.

Além de manter um alto nível de serviço, é de interesse das empresas manter seus custos baixos. Um dos maiores desafios da logística é o balanceamento entre bom atendimento e controle de custos, aspectos decisivos na avaliação de fornecedores. A boa gestão de estoques pode ajudar a alcançar esses dois objetivos, sendo um ramo onde se encontram oportunidades de redução de custo nas empresas desde que feita uma melhor gestão dos materiais armazenados e seu transporte (ARANGO et al., 2011).

Neste contexto, as organizações buscam firmar parcerias ao longo da cadeia de valor, tomando benefício das novas tecnologias de troca de dados empresariais para integração e melhor gestão de estoques (CLARK; HAMMOND, 1997). Uma das estratégias que vem sendo adotadas neste contexto é o Inventário Gerido pelo Fornecedor, do inglês *Vendor Managed Inventory* (VMI). Trata-se de um método de reposição de estoques onde fornecedor e cliente firmam uma parceria para gestão de inventário e controle da informação das ordens de compra e venda.

No VMI a gestão de estoques dos clientes passa a ser responsabilidade do fornecedor, o qual tomará decisões pré-autorizadas de abastecimento em nome do comprador. O cliente elimina a necessidade da atividade de gerenciamento dos seus estoques, deixando de incorrer nos custos associados a este processo e melhorando o nível de serviço de fornecimento (ÖZENER; ERGUN; SAVELSBERGH, 2013). Este sistema rompe com a forma tradicional de gestão de inventários, no qual os distribuidores decidem quanto, quando e de onde virá o

próximo abastecimento (ARANGO et al., 2011). Por isso, surge a necessidade da utilização de medidas contratuais para proteger o comprador em casos de falhas de abastecimento ocasionados pelo fornecedor responsável, com acordos jurídicos e multas, normalmente calculadas de acordo com o tempo em que o fornecido permaneceu sem possibilidade de produzir devido à falta de matéria prima.

Empresas fornecedoras atualmente oferecem este método de abastecimento como serviço extra de terceirização de decisões de estoque para possibilidade de diminuição na carga de trabalho para departamentos responsáveis por compras. Há também benefícios como maior controle do fornecimento a partir das informações de leitura de inventário. Isso possibilita melhorar as decisões internas, tais como gerenciamento de frota, além de trazer maior acurácia das taxas de demanda e notificação em caso de compra de produtos de concorrentes.

1.1 OBJETIVOS

1.1.1 *Objetivo Geral*

Avaliar métodos de previsão de demanda para auxiliar a decisão de reabastecimento dos tanques de clientes do setor petroquímico que trabalham com o estoque gerido pelo fornecedor.

1.1.2 *Objetivo Específico*

Como objetivos específicos deste trabalho de conclusão de curso, destacam-se:

- Testar a conformidade dos dados históricos com o método de previsão de demanda escolhido para elaboração do trabalho;
- Prover metodologias de decisão para auxílio no fluxo diário de trabalho de um fornecedor, se baseando em previsão de demanda;
- Avaliação do novo método de tomada de decisão, comparando com a demanda real realizada.

1.2 CONTRIBUIÇÕES E LIMITAÇÕES

Este trabalho apresentará um estudo de caso referente a uma empresa fornecedora de produtos químicos, a qual pretende utilizar previsão de demanda para apoio a escolha da data de abastecimento aos seus clientes com acordo de VMI. A empresa em questão já trabalha com este tipo de abastecimento, porém, a abordagem atual é bastante superficial e muito dependente do conhecimento do perfil de consumo do cliente pelo funcionário que gerencia seu inventário.

O estudo de caso tem por objetivo a identificação e avaliação de métodos para previsão de demanda para determinar o horizonte de abastecimento dos clientes. Para isso, serão usados os seguintes dados de entrada: leituras de volumes diários do tanque do cliente, tempo necessário para chegada do produto e capacidade máxima do tanque. Isso fará com que o fluxo diário de trabalho do analista responsável pelos inventários seja menos dependente de subjetividades e mais ágil, podendo assim aumentar a produtividade.

Atualmente, os funcionários fazem controle dos tanques dos clientes diariamente, no início do dia, por meio da integração do sistema de gestão de estoque MRP (*Manufacturing Resource Planning*, planejador de recursos de manufatura) da empresa compradora com o navegador de internet, ao qual o responsável pelo estoque tem autorização para leitura. Os dados de volume são inseridos em uma planilha interna, a qual realiza operações simples de adição e subtração para o registro dos níveis de consumo entre uma leitura e outra. O atual método é considerado pelos usuários muito simples. É reconhecido que esse processo poderia ser melhorado caso fosse aplicada uma metodologia de previsão de demanda para auxílio à decisão do período ideal de abastecimento do cliente.

Os dados referentes a seis meses de fornecimento em modelo VMI a uma empresa que consome os produtos químicos serão estudados, os quais serão testados em relação a adequação aos métodos de previsão de demanda de Holt-Winters, decomposição clássica da série de tempo (MMQ) com e sem sazonalidade, amortecimento exponencial simples, e médias móveis com e sem sazonalidade diária e redes neurais artificiais, onde qual apresentar maior precisão ditará as previsões apresentadas pela ferramenta desenvolvida para o estudo de caso.

Os clientes que optaram pelo atendimento em modelo VMI da empresa passam por uma reunião inicial em que são decididos os parâmetros de

abastecimento esperados e os quesitos legais ligados ao abastecimento. O cliente estabelece um estoque mínimo desejado, o qual é esperado que seu tanque não atinja níveis menores que esta quantidade. O tipo de transporte é definido, o que implica no tamanho das remessas que serão entregues (caminhão tanque, vagão ferroviário, container, entre outros). É feito então o acordo de crédito, onde as partes entram em consenso quanto ao método e horizonte de pagamento e verificam se é necessário impor limites de quantidade abastecida, normalmente com definição de um certo valor de fatura que, quando ultrapassado, deve ser interrompido ou reavaliado com as partes envolvidas.

Outro aspecto contratual relevante define uma multa caso a matéria-prima fornecida não se encontre à disposição do cliente para utilização, resultando em atraso no cumprimento da produção programada para o período. Este tipo de contrato costuma ser de natureza punitiva, visto que muitas empresas aderem ao VMI para que não precisem se preocupar com falta de matéria-prima, sendo que a falta de matéria prima deverá ocasionar uma multa bastante onerosa baseada na quantidade de horas produtivas perdidas devido à falta de abastecimento.

1.3 ESTRUTURA DO TRABALHO

Este trabalho traz uma revisão bibliográfica em seu segundo capítulo, no qual são listados os modelos de abastecimento mais comuns encontrados na indústria, com especial foco no VMI. O VMI possui uma sessão destacando sua aplicação, vantagens e desvantagens frente a outros modelos de fornecimento mais difundidos, apresentando embasamento bibliográfico para identificar viabilidade de implantação, bem como os benefícios que traria para um fornecedor e um comprador. Serão também apresentados métodos para previsão de demanda aplicáveis para apoio à decisão quando se trata do abastecimento VMI.

Em sequência, o capítulo 3 traz um estudo de caso, no qual serão apresentados os dados de volumes e pedidos de uma empresa fornecedora de produtos químicos que utiliza o VMI. A partir de sua análise, serão identificados os padrões de consumo, e efetividade de métodos de leitura. Será exposta a maneira com que a atividade de abastecimento é atualmente realizada, destacando a metodologia de decisão da data de abastecimento, planejamento de volume do pedido e as políticas quanto a data de carregamento da entrega.

Os resultados das avaliações dos métodos de previsão de demanda poderão ser vistos no capítulo 4, o qual apresentará um quadro com o erro médio quadrático de cada método para comparação.

A conclusão do trabalho é apresentada no capítulo 5, reservado às considerações finais.

2 REVISÃO DE LITERATURA

A utilização do VMI pode ser observada desde a década de 1990, quando os grandes varejistas internacionais como Wal-Mart, K-Mart e JCPenny utilizavam este método de reposição de seus estoques, na qualidade de clientes, de maneira pioneira (NOVAES, 2007).

A evolução dos sistemas integrados de informação no campo empresarial foi um fator importante para o crescimento e desenvolvimento das parcerias de fornecimento dos anos 90 para cá, tendo as tecnologias de EDI (*Electronic Data Interchange*) possibilitado cada vez mais integração dos fornecedores com a realidade de demanda do cliente fornecido (MONTEIRO, 2003).

O EDI é uma tecnologia da informação que segundo Spinola e Pessôa (1998) “cria um ambiente integrado e consistente, capaz de fornecer informações necessárias a todos os usuários”. Novaes (2001) destaca o EDI sendo inicialmente usado na década de 80 pelos setores de varejo e transporte nos Estados Unidos, expandindo mais tarde para os setores, automotivo e farmacêutico. A evolução desta ferramenta de comunicação empresarial teve papel fundamental na popularização da implantação dos sistemas de abastecimento mais inteligentes, visto que a produtividade e gestão de custos nos sistemas como VMI estão diretamente ligados com a rapidez e qualidade das informações trocadas entre os envolvidos. Dados do cliente como níveis de estoque, demandas confirmadas, demandas previstas e disponibilidade de espaço para armazenamento podem ser disponibilizados por meio da troca de dados entre os sistemas MRP (*Material Resource planner*) e WMS (*Warehouse Management System*) das empresas ou pela disponibilização na Internet dos formulários, método caracterizado como WEB EDI.

Publicações referentes à utilização do sistema VMI de reposição em produtos químicos são atualmente escassas. Foi feita uma pesquisa nos bancos de dados disponibilizados on-line pelo Portal de Periódicos do CAPES/MEC por termos como “logística VMI fluidos”, “VMI líquidos”, “VMI petróleo”, “VMI produtos químicos” e “VMI petroquímicos”, sendo o único resultado condizente com o assunto específico em língua portuguesa ou inglesa é uma publicação apresentada no *27th European Symposium on Computer Aided Process Engineering*, em 2017, com título traduzido “*Uma estrutura de decomposição para distribuição de fluidos por uma metodologia de inventário gerenciado pelo fornecedor*”. O artigo destaca os custos logísticos

envolvidos e a importância da utilização de ferramentas de otimização para diminuição destes, propondo um algoritmo de geração de colunas aninhadas (*nested column generation*) para planejamento da distribuição de fluidos químicos. (CÓCCOLA; MENDEZ; DONDO; 2017).

O problema de reabastecimento ótimo de estoques em VMI é apresentada por Standerski (2003). Foi feito um modelo em Fortran e resolvendo o problema com algoritmo genético. Seu modelo proposto comporta 4.000 clientes em horizonte virtualmente infinito, retornando com informações otimizadas de abastecimento para este problema em grande escala.

2.1 MODELOS DE FORNECIMENTO

Nas relações de fornecimento, diversas competências estão passíveis a avaliação para uma boa reputação como fornecedor. Abordagens mais antigas focam no desenvolvimento de um produto de qualidade, com menor preocupação com a forma que este chega ao consumidor, deixando em segundo plano importantes características do fornecimento como constância, confiabilidade, prazos, resposta a mudanças de cenário e forma com que lida com imprevistos.

Com o passar dos anos, as cadeias logísticas foram conquistando maturidade. Estudos foram realizados, grande parte puxados pela incessante busca por competitividade por parte das empresas, que procuram manter seus custos baixos ao mesmo tempo que evitam comprometer seu nível de serviço. Organizações têm se dado conta que a maneira com que a demanda do cliente é atendida se tornou tão importante quanto a qualidade do produto, colocando atividades de distribuição em importância semelhante à atividade de manufatura, quando se avalia a percepção de qualidade do fornecimento.

No contexto deste trabalho, o fornecedor é empresa provedora de matéria prima para um processo produtivo do cliente. É o responsável pela função de controle de estoque do cliente atendido pelo VMI, incluindo atividades de leitura de quantidade, pedido, transporte, descarregamento e geração de fatura. Além disso é necessário que este garanta a continuidade da produção, sob pena de quebra de contrato de fornecimento e multas por interrupção da produção.

A seguir, serão listados alguns dos modelos mais comuns de abastecimento de estoques para indústrias, destacando suas diferenças e aplicações. Também será apresentado o conceito do efeito chicote, bem como a interação deste com os modelos, visto que se trata de um fator importante para análise na tomada de decisão.

2.1.1 Traditionally Managed Supply Chain (TSS)

A cadeia de distribuição tradicional é ligada de cima para baixo no fluxo de materiais a serem fornecidos, de acordo com os pedidos lançados, que caminham de baixo para cima (DISNEY; TOWILL, 2003). As organizações que optam por este método estão totalmente em controle de seus inventários, sem nenhuma relação profunda com nenhum fornecedor. Seu setor interno dedicado ao inventário para a produção é o responsável pelos pedidos e cronogramas de abastecimento, com o mínimo de troca de dados com os fornecedores envolvidos.

O problema comum deste sistema é o isolamento e a escassez de informações disponíveis aos envolvidos, visto que cada um é responsável pelo seu estoque apenas e dispõe de menos ferramentas para melhorar seu nível de preparo frente aos desafios ocasionados pela oscilação de demanda do mercado.

A gestão de uma cadeia tradicional pode sim ser informatizada em seus estoques e dispor de metodologias de previsão de demanda. Porém, por não serem alimentadas por dados externos provenientes de parcerias concretas, as previsões não oferecem tanto apoio ao gerenciamento de quantidades frente a oscilações de demanda, como ofereceriam os dados diretos de leituras de estoque em tempo real (VMI).

O gerenciamento tradicional do fornecimento ainda é muito utilizado em diversos setores. Em muitos casos, seu uso reflete o receio das empresas no referente ao compartilhamento de dados, visto que informações relevantes de giro de estoque podem ser indicadores de saúde financeira e situação de mercado. Outras críticas advêm da preferência de algumas organizações de estarem totalmente em controle de seus materiais, possibilitando jogadas mais flexíveis, trabalhos com escassez de material de forma proposital ou estocagem de mais

materiais para preparação para futuras incertezas, políticas decididas internamente entre os setores de produção e armazenagem.

Esta metodologia é bastante viável em alguns setores e em algumas faixas de volume de vendas, porém, em outras realidades, pode se mostrar demasiadamente simples e insuficiente para um bom nível de serviço. Cabe aos gestores avaliar à médio e longo prazo a implantação de parcerias mais sofisticadas que atendam de forma mais eficiente aos desafios específicos das demandas do seu setor.

2.1.2 Collaborative Planning, Forecasting and Replenishment (CPFR)

Na tentativa de alinhar todos os membros da cadeia de abastecimento com a real demanda do consumidor final, foi estabelecida em diversas empresas a iniciativa de planejamento, previsão e reabastecimento colaborativo (do inglês CPFR). O CPFR é uma alternativa ao modelo tradicional e ao VMI, que se assemelha deste último por também buscar a construção de uma parceria entre fornecedor e comprador mais integrada e menos conflituosa. Ambas foram impulsionadas pelos avanços nas tecnologias da informação empresarial.

O CPFR é uma iniciativa de colaboração baseado em inovação tecnológica que auxilia na integração e padronização dos processos para uma comunicação eficaz, nos níveis estratégico, tático e operacional (TAVARES; LIMA, 2006). Seu objetivo principal é aprimorar o relacionamento por meio da gestão integrada dos processos de planejamento e informação. O planejamento da reposição de estoque se dá pelos envolvidos tomando decisões em conjunto, reunindo fabricantes, distribuidores e comerciantes na definição da previsão de demanda e reposição de produtos.

Tavares e Lima (2006) também destacam que em produtos com pouca diferenciação entre fabricantes (*commodities*), os quais apresentam o preço como principal fator de escolha, o CPFR não se mostra vantajoso. O modelo tem como característica os benefícios a longo prazo, estabelecendo um ambiente de integração e vantagem mútua para aumento de nível de serviço, abrindo mão assim das vantagens de curto prazo como a negociação de preço com distribuidores trazendo ofertas promocionais.

Comparado ao VMI, o planejamento colaborativo dissolve a autonomia do fornecedor na tomada das decisões de abastecimento cotidianas, apresentando um padrão de empoderamento igualitário entre fornecedor e fornecido no planejamento do horizonte de abastecimento. Do ponto de vista de um fornecedor, abrir mão deste poder de decisão significa menos alternativas de planejamento de suas rotas e estoques dedicados ao cliente, limitando suas decisões que poderiam trazer diminuição de custos de frete, carregamento, mão de obra, estoques e pedidos. Quanto à abertura de informações e os problemas que isso pode trazer, o planejamento colaborativo exige menor exposição do comprador, visto que reuniões e decisões em conjunto são menos sensíveis do que a abertura de parte de seu MRP ao fornecedor para que este tome decisões por você, sendo esta uma desvantagem do VMI do ponto de vista do fornecido.

2.1.3 *Continuous Replenishment Program (CRP)*

Um dos métodos comuns de colaboração na cadeia de suprimento é o programa de reabastecimento contínuo, do inglês *Continuous Replenishment Program (CRP)*. Adotado por diversas organizações de variados setores, este acordo de colaboração coloca sob responsabilidade do fornecedor o abastecimento dos estoques do cliente de acordo com as informações de vendas realizadas e os níveis de estoque observados no período (PARSA et al., 2017).

Diversas semelhanças podem ser observadas entre o CRP e o VMI. Ambas apresentam como característica a eliminação da necessidade de a empresa fornecida postar ordens de compra, sendo as decisões de abastecimento para atendimento das exigências de nível de inventário guiadas pela troca de informações via EDI (CLARK; HAMMOND, 1997). Ambas iniciativas necessitam de investimentos iniciais para implantação, principalmente no que se refere a implantação dos sistemas de comunicação, que por vezes envolvem sensores, EDI e *softwares* de gerenciamento de estoque. Porém, podemos entender como principal diferença o abastecimento contínuo sendo algo literalmente contínuo, com a obrigação do fornecedor de repor o estoque conforme ele é consumido, enquanto no VMI, o fornecedor tem a possibilidade de administrar de acordo com a estratégia que melhor se adapte com a realidade do cliente, desde que não falte material.

Porém, dentre as desvantagens da utilização do CRP, Clark e Hammond (1997) destacam que as demandas precisam apresentar estabilidade ou razoáveis níveis de previsibilidade para gerarem bons resultados. Também é válida a preocupação com a necessidade de abertura dos seus registros de vendas com seu fornecedor, informação bastante sensível, pois serve como indicador direto quanto a sua competitividade como empresa (RAGHUNATHAN; YEH, 2001).

Enquanto o VMI é ligado de maneira mais forte ao nível do armazém, o CPR é mais fortemente relacionado às vendas da empresa fornecida. Isto significa que, em alguns contextos, como na aplicação apresentada no estudo de caso deste trabalho, o CPR não apresenta tanta atratividade. As empresas abastecidas são do setor industrial, o que normalmente significa que entre a venda ser realizada e o estoque de matéria prima precisar ser abastecido há um maior intervalo de tempo, devido ao tempo de atravessamento. Assim, o VMI, por apresentar como indicador o nível de disponibilidade do material que entrará no processo, se mostra mais vantajoso e mais popular no segmento.

2.1.4 Vendor Managed Inventory (VMI)

O VMI, Inventário Gerido pelo Fornecedor, por vezes chamado de abastecimento contínuo, é uma das iniciativas de parceria empresarial mais discutidas para aprimoramento da eficiência da cadeia de abastecimento. Popularizado ao final da década de 1980 pelo Walmart e pela Procter & Gamble (WALKER, 1999), se tornou um aspecto chave do setor varejista para busca da eficiência na resposta ao consumo.

Na política de VMI, o fornecedor, no papel de fabricante ou por vezes de revendedor ou distribuidor, toma as decisões de reposição de estoque para a entidade consumidora. Isto significa que este deve monitorar os níveis de inventário para embasar suas definições de quantidades de pedidos, volume e prazo para abastecimento.

Apesar de bastante utilizado para abastecimento do setor varejista, este modelo também é utilizado no setor de manufatura. No estudo de caso a seguir será abordada uma empresa fabricante de produtos petroquímicos que utiliza da leitura dos tanques de estoque do cliente para tomada de decisão de abastecimento.

É válido salientar que o controle de estoque e todas as decisões referentes a garantia da disponibilidade de matéria prima em um sistema produtivo exige considerável quantidade de horas de trabalho de gestores qualificados na manutenção deste. Com a terceirização de muitas decisões referentes a este controle, atividades recorrentes e operacionais não farão mais parte da responsabilidade do cliente. Isto diminui a necessidade e demanda por colaboradores capacitados para controle corriqueiro das rotinas de abastecimento da empresa compradora.

Dentre as vantagens destacadas por Novaes (2007), pode se destacar a redução do nível médio de estoque no cliente, diminuição de ocasiões de falta de material e grande diminuição do tempo de espera pelo material. Além disso, são identificadas vantagens para o fornecedor, as quais envolvem possibilidade de diminuição do seu estoque. Isto se deve à utilização de dados diretos do cliente, o que diminui o nível de incerteza e a dependência de dados históricos para previsão de volumes.

É importante salientar em conta o aspecto de fidelização ocasionado pelo VMI. Ao habilitar acesso aos dados de estoque a um fornecedor, seja por meio de sensores, conferência presencial ou interligação de MRPs (*material resource planner*), este saberá se houveram ocasiões em que o abastecimento foi originário de uma empresa concorrente. Ao identificar tal abastecimento por um terceiro, a empresa provedora poderá tomar uma ação frente a este indicador, bem como identificar os motivos pelos quais tornou-se necessária a compra por meio de outra fornecedora.

No que se refere às razões para que o VMI ainda não esteja presente em maior quantidade de organizações, Serna, Jaime e Portilla (2011) citam que a resistência se deve à necessidade de compartilhamento de informações muito sensíveis, como nível de inventário, custos operacionais e previsões de demanda, consideradas informações estratégicas. Tais informações podem levar a conclusões confidenciais quanto a expectativas de crescimento ou decréscimo da empresa, bem como abrangência no mercado, o que justifica que sua implantação só faz sentido se os envolvidos estiverem em uma relação segura de parceria e confiança (TAVARES; LIMA, 2006).

2.1.5 O Efeito Chicote

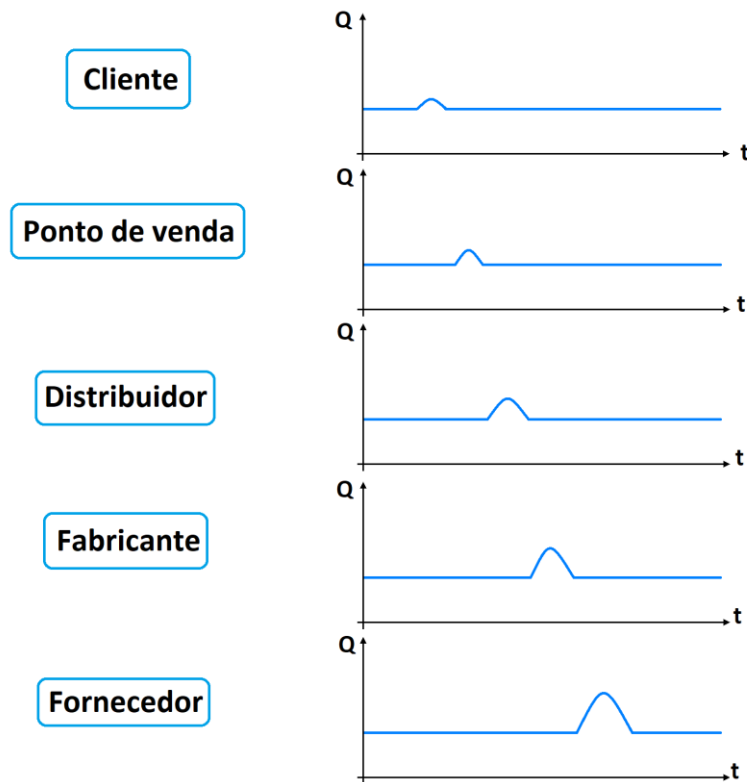
A empresa estudada neste trabalho, que atua no fornecimento de produtos químicos derivados do petróleo, precisa estar atenta aos perigos deste efeito, sendo necessário o uso de algumas técnicas para mitigação dos danos provenientes das distorções de demanda.

Enquanto se identifica um aprimoramento nas metodologias de fluxo de materiais, igual atenção não foi direcionada na otimização do fluxo de informação ao longo da cadeia de fornecimento. Essa desatenção de alguns métodos de abastecimento tem gerado o chamado *bullwhip effect*, o efeito chicote.

O efeito chicote advém da falta de alinhamento da demanda à oferta nos diversos níveis da cadeia de abastecimento. Coelho, Follman e Rodriguez (2009) definem efeito chicote como “resultado de uma expectativa de demanda ou oferta que não se realiza”, podendo isso ser resultado principalmente da falta de sucesso na previsão de demanda do consumidor final.

Variações específicas nos padrões de consumo podem ocasionar esse efeito. Produtos finais que experienciam um aumento pontual de demanda podem levar varejistas a se precaver com uma compra acentuada deste produto no próximo período. O distribuidor, ao perceber essa maior procura do varejista, dispara um pedido maior que o usual ao fabricante para evitar a falta do produto. O fabricante por sua vez, amplifica o efeito, produzindo peças a mais para se preparar para abastecer os distribuidores futuramente, ocasionando uma maior compra de matéria-prima por seus fornecedores. Este aumento de demanda, quando concretizado, não costuma causar efeitos negativos, porém, quando mal previsto, desencadeia problemas ao longo de toda a cadeia de abastecimento. Tal crescimento pode ser visto na Figura 1, que relaciona a quantidade de estoque deslocado pelo horizonte de tempo da análise.

FIGURA 1 - O EFEITO CHICOTE



Fonte: O Autor (2019)

O efeito chicote tem uma natureza crescente conforme se transfere para os envolvidos, se tornando por vezes bastante acentuado ao atingir os fornecedores de matéria-prima industrial, sendo assim uma preocupação constante do fornecedor abordado no estudo de caso.

Sari (2007) destaca que a redução do efeito chicote tem papel vital na competitividade no fornecimento. Dentre os efeitos negativos, é possível observar altos níveis de inventário e baixa rotatividade de estoques, além de, em casos mais graves, a alta produção para uma demanda não concretizada incorrer em custos como hora extra e energia.

Disney e Towill (2003) afirmam que o uso do VMI diminui as consequências negativas do efeito chicote por duas frentes: primeiro pela eliminação de uma camada de tomada de decisão, e em segundo pela eliminação dos atrasos da

comunicação entre mais componentes da cadeia. Estas medidas agem no principal gerador da acumulação de erros, a distorção dos dados.

2.2 VANTAGENS E DESVANTAGENS DA UTILIZAÇÃO DO VMI

2.2.1 *Vantagens Observadas pelo Fornecedor*

Grandes empresas que prestam serviço de fornecimento comumente disponibilizam mais do que um modelo de abastecimento para seus clientes, para que este avalie qual metodologia se encaixa melhor à sua realidade de demanda e política de estoque do dado produto. É interessante ser flexível a ponto de poder oferecer opções personalizadas quando se trata do aumento de volume de vendas e abrangência de mercado.

A colocação de clientes em modelo VMI tem como uma de suas principais vantagens a maior possibilidade de geração de previsões de demanda para sua própria produção. Dados diretos de utilização de seus produtos pelos compradores permite um melhor planejamento do volume de produção, visto que são dados fieis e diretos, sempre disponíveis para consulta.

Fornecedores costumam ter interesse estratégico em alguns clientes que têm a possibilidade de implantação do VMI pelo aspecto de fidelização causado. Ao firmar o acordo de abastecimento gerenciado pelo vendedor, este se torna o único responsável pelas vendas deste produto. Em cadeias tradicionais (TSS), o comprador pode ter um leque de fornecedores possíveis, tomando periodicamente a decisão de qual ou quais serão os escolhidos no determinado período, levando em conta preços e promoções pontuais. No VMI, já é acordado que o abastecimento será proveniente apenas do parceiro estabelecido. Este aspecto é comum quando empresas de pequeno ou médio porte se relacionam com grandes fornecedores.

Nesta mesma linha de pensamento, caso, por algum motivo, o cliente compre matéria prima de outro fornecedor, o gerenciador de inventário será instantaneamente alertado por meio de uma subida no nível de estoque não realizada por ele. Isto permite diagnosticar os motivos da escolha de outro fornecedor, como promoções e facilidades, permitindo tomar medidas para conservação do cliente antes de perdê-lo para concorrência.

Ao adaptar sua empresa para possibilitar o oferecimento do VMI, implantando as tecnologias necessárias, a busca por clientes interessados nesta metodologia se torna mais atraente. A dissolução dos custos desta instalação inicial e a obtenção de tecnologias para decisão automatizada, que possibilitam gerenciamento eficiente vários clientes, auxiliam na economia de escala, contribuindo com a lucratividade.

Em algumas famílias de produtos, gerenciar o abastecimento dos seus clientes possibilita a criação de rotas otimizadas entre eles, com a liberdade de escolha da quantidade e da janela de horário em que cada um será atendido. Diversos custos relacionados ao frete podem ser diminuídos com a otimização do roteamento, visto que liberdades como estas significam menos restrições na modelagem do problema de roteamento (NOVAES, 2007).

Por último, porém não menos importante, é possível citar a menor vulnerabilidade frente ao efeito chicote. A redução deste efeito pode ser considerada a motivação para implantação das diferentes parcerias de abastecimento (LEE et al., 1997). Sendo um fornecedor de matéria prima industrial, ou seja, considerado o último na cadeia produtiva, as distorções de demanda podem se apresentar de maneira bastante amplificada. A retirada de um dos componentes nesta rede por meio da atuação como gestor de estoque um degrau abaixo faz com que essas imprecisões sejam reduzidas.

2.2.2 Desvantagens Observadas pelo Fornecedor

Ser o tomador de decisão de abastecimento em nome de um cliente gera custos. Oferecer o serviço de gerenciamento de estoques de clientes ocasiona uma necessidade de pessoal capacitado não presente em modelos tradicionais de venda. Este serviço extra deve ser incorporado nos custos de fornecimento e não pode ser ignorado na precificação do produto.

Há também a possibilidade de ônus devido à multa por falha em abastecer o cliente. Assim como na cadeia tradicional, a impossibilidade de produção por conta de um fornecedor não cumprindo com seu papel é passível de multa, quando previsto no contrato de fornecimento. A desvantagem é que utilizando VMI, existe não só o perigo da ordem não chegar a tempo por imprevistos durante o transporte,

mas também pela não postagem da ordem de compra em tempo, problema que antes seria do cliente.

2.2.3 Vantagens Observadas pelo Cliente

Empresas que escolhem firmar parcerias VMI para seu abastecimento podem escolher quais produtos entrarão nesta metodologia e quais, por ventura, serão geridos internamente. Decisões deste tipo podem ser embasadas no quanto a matéria prima é exclusivamente oferecida por uma empresa ou o quanto ela é comum em diversos fornecedores, o que despertaria interesse em comprar de quem oferece melhores vantagens pontualmente.

A primeira vantagem é a simplificação do gerenciamento dos seus estoques, visto que agora este será terceirizado. A mão de obra referente às medições de quantidade de produtos e postagem de ordens de compra poderão ser diminuídas ou eliminadas.

Novaes (2007) destaca que a velocidade geral do pedido é melhorada. Pulando a etapa de postagem de ordens de compra e conferências quanto a capacidade disponível para entrada de materiais, o *lead-time* é fortemente diminuído.

Em estoques gerenciados internamente, caso ocorram erros de previsão, quantidade pedida ou atraso na postagem do pedido, corre-se o risco de parada no processo produtivo que utiliza da matéria prima que não está disponível. Utilizando o VMI, problemas como estes são menos comuns, e quando ocasionados, as perdas pelo atraso na produção serão oneradas ao fornecedor em forma de multa por não cumprimento do contrato de fornecimento.

Fornecedores costumam incentivar a implantação do VMI para se garantirem como único fornecedor. Esta fidelização ocasiona aumento do volume de compra, o que reflete em maior poder de negociação e melhores preços.

E por último, ainda existe a impossibilidade de aproveitar brigas de preços de outros fornecedores. Ao firmar uma parceria de abastecimento, fica implícito que o responsável pelo seu inventário tomará todas as decisões referentes às suas compras e este será seu fornecedor único. Isto impossibilita o proveito de promoções divulgadas pelos outros fornecedores disponíveis.

2.2.4 Desvantagens Observadas pelo Cliente

São destacadas como desvantagens principais primeiramente o custo de implantação e manutenção das tecnologias necessárias para boa comunicação empresarial. Sensores, *softwares* e sistemas EDI têm um custo associado que não se mostra viável em realidades de pouco volume ou pouca melhoria na eficiência.

Outro aspecto importante é a necessidade de divulgar com outra empresa seus níveis de estoque, informação tradicionalmente classificada como sensível pelas organizações (RAGHUNATHAN; YEH, 2001). A exposição destes dados pode sinalizar à agentes externos informações sigilosas da empresa, como a passagem por períodos de fragilidade ou de expansão.

É importante ressaltar os cuidados e a responsabilidade durante a leitura de dados dos clientes. Além da necessidade de segurança para não vazamento de informações confidenciais da empresa fornecida, ser responsável por esse tipo de medição transfere ao fornecedor requisitos quanto a qualidade e precisão das medições. Quando é referida a produtos petroquímicos líquidos, a medição dos volumes nos tanques dos clientes é sujeita a variações pontuais de nível devido à agitação do produto, causado por sucção ou borbulhamento, ou ainda pelo aumento de volume causado pela temperatura de operação de maquinário acoplados ao tanque.

Para mitigar este tipo de imprecisão, o responsável pela coleta do nível precisa estar ciente do método de medição utilizado no tanque, sendo que cada metodologia tem suas vantagens e desvantagens, sendo assim necessária uma avaliação individual das especificidades. Dentre os métodos de medição de volume em tanques mais comuns, pode-se citar boias de nível, ultrassom (TOMECEK, 1989), diferença de pressão interna (FERRETTI; GABEL; HORTON, 1986) e capacitância (ENDRESS; HAUSER, 2017). Uma medida simples de prevenção de erros de medição é a coleta do nível de tanque em momentos em que a linha de produção não esteja exigindo o produto estocado, prevenindo assim os efeitos causados pela sucção e temperatura no produto líquido em questão.

2.3 PREVISÃO DE DEMANDA

No âmbito industrial, o conhecimento prévio de estimativas dos volumes futuros é peça fundamental no controle de estoques. Segundo Novaes (2007), o planejamento dos processos de abastecimento depende de estimativas de como a demanda se comportará no futuro, de forma que a cadeia de distribuição dependerá dela de ponta a ponta.

As matérias primas, mão de obra, escoamento, pontos de venda, publicidade, instalações, depósitos, recursos financeiros e diversos outros componentes podem se beneficiar de uma previsão bem estruturada. Tais projeções podem gerar ganhos em tempo de atendimento, diminuição de estoques intermediários, redução de casos de não atendimento, menor necessidade de uso de instalações físicas, cálculos de lote econômico e melhor utilização do capital, sendo que todos esses quesitos podem refletir em vantagens competitivas, econômicas e financeiras.

Quando é avaliado o abastecimento baseado em VMI, é a empresa gestora do estoque que estará sujeita à maior parte dos benefícios gerados por uma consolidada metodologia de previsão de demanda. A possibilidade de promover uma regra quantitativa comum aos seus clientes possibilita replicar a economia gerada pela boa otimização do ponto de pedido, tornando o fluxo de trabalho do gestor mais fluído e menos passível a erros. Isto se deve à menor necessidade de conhecimento específico quanto à operação da empresa gerida, visto que os métodos matemáticos darão o panorama de demanda de forma mais confiável do que as subjetividades de um analista de estoques que não tem contato direto com o armazém.

É válido ressaltar que é desejável que a natureza da demanda analisada seja regular para que a aplicação de métodos matemáticos alcance melhores resultados, visto que demandas irregulares têm natureza incerta e dificilmente serão identificados padrões consistentes ao longo do tempo estudado (BALLOU, 2006).

A previsão utilizando séries temporais funciona tentando identificar padrões ao longo do tempo combinados com um grau de erro aleatório, de modo a separar esses dois componentes para compreender suas tendências, sazonalidades e flutuações de demanda (KALEKAR, 2004).

Pode-se dividir as técnicas em qualitativas e quantitativas. As técnicas qualitativas de previsão de demanda fazem análises estratégicas de mercado, levando em consideração perspectivas e cenários, incluindo questões políticas, concorrência e aceitação de produtos, muito útil quando não estão disponíveis dados históricos para embasamento de previsões matemáticas. Já as técnicas quantitativas, necessitam de dados temporais anteriores para formulação de um modelo que em teoria, será uma projeção dos padrões já identificados, como tendência, aleatoriedade e sazonalidade (BALLOU, 2007).

Este trabalho usa metodologias quantitativas para definição das datas de pedido de reabastecimento, visto que o conhecimento da utilização da matéria prima do cliente quase sempre se resume ao seu histórico de consumo. Nada impede que ambas modalidades sejam empregadas em conjunto, completando o panorama para uma melhor definição de cenário. Uma situação exemplo seria quando a empresa abastecida comunica que estará ampliando a linha de produção que utiliza do material em questão, já sinalizando uma tendência de aumento no consumo e conseqüentemente, na necessidade de reabastecimento. Este aumento provavelmente não poderia ser identificado apenas analisando matematicamente os padrões de consumo anterior, justificando assim o benefício de dados qualitativos.

2.3.1 Médias Móveis

Consiste em uma média aritmética ou ponderada de pontos consecutivos anteriores da série. Segundo Ballou (2006), pode se mostrar interessante em horizontes de curto prazo de previsão e de acordo com o número de pontos de dados escolhidos, pode eliminar os efeitos da sazonalidade e irregularidade. Não é indicada em séries com componentes de tendência e sazonalidade.

Pontos anteriores ao próximo dado a ser previsto são escolhidos de acordo com o valor de n escolhido, sendo a previsão o valor da média destes n pontos anteriores conforme Equação (1). Pode-se também utilizar a média móvel dupla, onde o valor de previsão é a média móvel das médias móveis das observações anteriores, mostrando valores menos sensíveis a aleatoriedades pontuais e com maior tempo de reação às tendências.

$$S_t = \frac{X_{t-1} + X_{t-2} + X_{t-3} + \dots + X_{t-n}}{n} \quad (1)$$

- Sendo S_t o valor previsto para o período atual;
- n é o valor de observações anteriores que serão consideradas;
- $X_t - 1$ é o valor observado 1 período atrás, $X_t - 2$ o valor observado 2 períodos atrás e $X_t - n$ o valor observado n períodos atrás.

2.3.2 Decomposição Clássica da Série de Tempo (MMQ)

Este é um dos métodos mais populares de ajuste de dados a uma reta, que permite interpolação e extrapolação de valores de acordo com a tendência identificada na seleção inicial de dados que contenham uma relação linear entre si. Também conhecido como método dos mínimos quadrados em outras aplicações de outras áreas do conhecimento. Segundo Helene (2006), a decomposição clássica consiste em encontrar valores de a e b que minimizam o erro (soma das diferenças quadráticas) entre a reta gerada e os valores inicialmente observados. O componente a define a inclinação da reta gerada, enquanto o componente b o valor de y inicial de onde a inclinação será aplicada.

A Equação 2 apresenta o cálculo do coeficiente a , a Equação 3 do coeficiente b e a Equação 4 retorna o valor previsto, onde todos os somatórios se referem de $i = 1$ até n .

$$a = \frac{N(\sum x_i y_i) - (\sum x_i) * (\sum y_i)}{N(\sum x_i^2) - (\sum x_i)^2} \quad (2)$$

$$b = \frac{(\sum y_i) * (\sum x_i^2) - (\sum x_i y_i) * (\sum x_i)}{N(\sum x_i^2) - (\sum x_i)^2} \quad (3)$$

$$S_t = a * i + b \quad (4)$$

- Onde a é o valor a ser multiplicado pelo período em questão;
- b é o valor a ser adicionado à multiplicação do componente linear pelo período;
- N é o número de observações;

- $\sum x_i y_i$ é o somatório de todos os componentes x multiplicados aos componentes y ;
- $\sum x_i$ é o somatório dos componentes x ;
- $\sum y_i$ é o somatório dos componentes y ;
- $\sum x_i^2$ corresponde ao somatório dos componentes x após serem elevados ao quadrado;
- E S_t retorna o valor previsto para o período i .

Quando o método é utilizado para realização de previsões, são gerados os dois parâmetros de acordo com os dados históricos cruzados com o período de tempo referente a tal observação. Posteriormente, os componentes a e b são utilizados para obter uma linha de tendência que poderá indicar onde as próximas observações poderão estar distribuídas, caso estas sejam condizentes com o perfil de demanda anterior.

A decomposição clássica por si só não possui nenhum ajuste para sazonalidade, visto que se trata apenas de uma linha de tendência. É possível acrescentar índices de sazonalidade posteriormente nas previsões, os quais podem ser multiplicados aos valores gerados pela tendência do método para buscar maior adequação às séries de dados onde é perceptível uma variação de acordo com o período sazonal.

2.3.3 Amortização Exponencial Simples

As técnicas de amortização exponencial consistem em um cálculo recursivo onde a previsão é atualizada a cada nova observação. Ela quantifica os dados recentes e diminui exponencialmente sua relevância de acordo com o tempo decorrido desde sua observação.

A amortização exponencial simples consiste em uma previsão de mais curto prazo utilizando apenas um parâmetro α . O modelo assume que os dados estarão em torno de uma média estável, sem o uso de tendências de crescimento ou diminuição de demanda. A previsão por amortização exponencial simples é dada pela Equação (5):

$$S_t = \alpha * X_{t-1} + (1 - \alpha) * S_{t-1} \quad (5)$$

- Sendo S_t o valor da previsão para o período atual;
- X_{t-1} a demanda real para o período $t - 1$;
- α o parâmetro de amortização;
- S_{t-1} a previsão realizada para o período anterior.

O parâmetro α , que varia entre zero e um, define o quanto as observações anteriores influenciarão na previsão do valor médio futuro. Valores de α mais próximos a zero levam menos em consideração as últimas observações, enquanto que valores próximos a um utilizam de maneira mais intensiva as últimas demandas reais observadas.

É interessante a utilização de uma metodologia de minimização de erros para escolha do valor do parâmetro α , utilizando como função objetivo a diminuição de erros (diferenças entre valores reais e observados), com intuito encontrar um α que demonstre melhor adaptação para observações futuras.

2.3.4 Amortização Exponencial Tripla – Holt Winters

Trata-se de um método utilizado para séries de dados que demonstram tendência ao mesmo tempo que sazonalidade. Utiliza-se de três parâmetros para modelagem: O α , referente ao nível, β que está associado à tendência e o γ , que está ligado à sazonalidade dos dados (KALEKAR 2004). Os parâmetros do método variam entre zero e um e podem ser calibrados por otimizações com função objetivo minimizar o erro, a fim de encontrar valores que em tese se mostrarão condizentes com a série estudada e poderão ser usados para a previsão dos períodos futuros.

O método de Holt-Winters não é robusto quando existem valores discrepantes (*outliers*) dentre as medições (GELPER; FRIED; CROUX 2009). Valores muito abaixo ou muito acima do esperado para determinado período resultam em rápida deterioração da confiabilidade do modelo. Devido à natureza de identificação de padrões sazonais e de tendência do método, cuidados devem ser

tomados para que os valores que substituam os discrepantes sejam condizentes com as observações já realizadas em períodos equivalentes no passado.

Para o cálculo das previsões pelo método de Holt-Winters, são utilizadas as equações 6, 7 e 8 que calculam a componente de nível, tendência e sazonalidade, respectivamente, além da Equação 9 que une os três componentes para resultar o valor previsto. Sendo elas:

$$L_t = \alpha \left(\frac{Y_t}{S_{t-M}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (6)$$

- Sendo L_t o componente de nível (*level*) do período atual;
- α o parâmetro de nível;
- Y_t o valor da observação atual;
- S_{t-M} a observação anterior correspondente ao mesmo período sazonal;
- L_{t-1} o componente de nível do período anterior;
- T_{t-1} o componente de tendência do período anterior.

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (7)$$

- Sendo T_t o componente de nível (*trending*) do período atual;
- β o parâmetro de nível;
- L_t o componente de nível do período atual;
- L_{t-1} o componente de nível do período anterior;
- T_{t-1} o componente de tendência do período anterior.

$$S_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma)S_{t-M} \quad (8)$$

- Sendo S_t o componente de sazonalidade (*seasonality*) do período atual;
- γ o parâmetro de sazonalidade;

- S_t o valor da observação atual;
- L_t o componente de nível do período atual;
- S_{t-M} a observação anterior correspondente ao mesmo período sazonal.

$$F_{t+k} = (L_t + k * T_t) * S_{t-M+k} \quad (9)$$

- Sendo F_{t+k} a previsão para o período futuro;
- L_t o componente de nível para o período atual;
- k o número de períodos em avanço que serão previstos;
- T_t o componente de tendência do período atual;
- S_{t-M+k} o componente de sazonalidade, da observação anterior correspondente ao mesmo período sazonal.

2.3.5 Redes Neurais Artificiais

Inspiradas nas capacidades do cérebro humano de aprendizagem e generalização, as redes neurais artificiais (RNA) têm se mostrado uma poderosa ferramenta para identificação e replicação de padrões (ZHANG; PATUWO; HU, 1998). São capazes de aprender com as informações de entrada e criar sutis relações entre os dados que dificilmente seriam percebidas por outros métodos de previsão.


Trata-se de uma metodologia, que entre outras aplicações, pode ser utilizada para previsão de demanda, que exige uma fase de aprendizagem na qual é apresentada às séries de dados para análise e utilização como exemplo, que serão posteriormente utilizados na geração de previsões condizentes com os padrões identificados nos dados de entrada.

Elas podem ser divididas em dois grandes grupos, as dinâmicas e as estáticas. As redes estáticas, grupo na qual a MLP (*Multi Layer Perceptron*) é a mais utilizada, é caracterizada por equações em nós sem utilização de memória, ou seja, resulta apenas da informação corrente, não utilizando as entradas passadas ou futuras em suas previsões. As redes dinâmicas, por outro lado, são caracterizadas

por sistemas com memória, com equações de nós tipicamente descritas como diferenciais (HUSH; HORNE, 1993).


As RNA também podem ser classificadas de acordo com o número de camadas, como destacado por Braga, Carvalho e Ludemir (2011). As redes de camada única são formadas por apenas uma camada de saída da rede, como pode-se ver na Figura 2. De forma análoga, as redes de múltiplas camadas são compostas por mais de uma camada entre a entrada e a saída da rede, como pode-se analisar na Figura 3.

FIGURA 2 – Exemplo de rede de camada única



Fonte: Adaptado de Braga, Carvalho e Ludemir (2011)

FIGURA 3 – Exemplo de rede de múltipla camada



Fonte: Adaptado de Braga, Carvalho e Ludemir, 2011

Os sinais de entrada de uma RNA, que podem ser representados por $x_1, x_2, x_3, \dots, x_n$, ao chegarem em um neurônio, são multiplicados pelos respectivos pesos sinápticos $w_1, w_2, w_3, \dots, w_n$ e acrescidos do parâmetro de viés b , nos trazendo um valor de z , chamado de potencial de ativação, como podemos observar na equação (10) a seguir:

$$z = \sum_{i=1}^n x_i w_i + b \quad (10)$$

O valor de z obtido passa então por uma função de ativação, responsável por limitar z a um certo intervalo, gerando assim a saída y do neurônio.

Para a formação de uma rede neural multicamadas (MLP, *Multi Layer Perceptron*), tais neurônios são organizados em camadas, cada qual com um número correspondente de neurônios. As entradas x são processadas pela camada inicial, a qual fornecerá seus resultados como entradas para a próxima camada, sucessivamente, até a obtenção da saída da última camada.

O *backpropagation* é um mecanismo de calibração dos valores do vetor w dos neurônios, responsável pelo refinamento do resultado a cada iteração realizada. De trás para frente, a última camada tem seus valores de w recalculados, para que então as camadas intermediárias possam também ser calibradas, até que se chegue a primeira camada, com o intuito de minimizar o erro durante a fase de treinamento

da rede. Ao comparar os valores obtidos com os valores esperados durante o processo de aprendizagem, a função de erro, que deve ser diferenciável, apresentará seu vetor gradiente (isto é, direção de maior crescimento), o qual o seu sentido contrário indicará parâmetros de w que resultarão na minimização da função erro.

Dentre as vantagens da utilização das redes neurais para previsão de demanda, pode ser citada a menor necessidade de constante retreinamento e recalibração dos parâmetros que regem a série temporal (YE; KEOGH, 2009), visto que modelos que utilizam parâmetros de tendência, nível e/ou sazonalidade necessitam de constante otimização destes parâmetros ao serem adicionados novos dados de entrada.

2.3.6 Outliers

Ao estudar uma série de dados temporais, é possível que sejam encontrados valores extraordinários não compatíveis com o comportamento esperado das medições. No processo de aplicação de técnicas de previsão de demanda, é adequado analisar os dados referentes a demandas atípicas, para que as anormalidades não venham a interferir a precisão do método de forma tão negativa (SOUZA, 2010).

Os *outliers*, ou valores discrepantes, podem ser causados por diversos fatores. O primeiro deles é o erro de medição, ocasionado quando a coleta de dados não é feita de forma precisa ou calibrada. Fatores imprevisíveis como greves, boicotes a produtos, problemas mecânicos e acidentes em geral podem gerar demandas atípicas em diversos setores que poderiam se beneficiar de previsões de demanda.

Na série de dados do estudo de caso, são encontradas medições discrepantes. Pode-se destacar três situações em que elas ocorreram:

- Erro de medição pela agitação: Valores negativos foram observados, principalmente aos domingos, onde o consumo na maioria das vezes seria nulo. Isto pode ser explicado pela agitação do líquido ocasionada pela sucção proveniente da máquina seguinte ao tanque, que faz com que as boias de medição mostrem valores imprecisos. Tais agitações não acontecem em dias sem produção.

- Alteração de volume pela temperatura: Assim como a alteração pela agitação, acontece devido ao maquinário acoplado à tubulação do tanque de armazenamento. Por se tratar de produtos líquidos, o volume tem grau de variação de acordo com a temperatura em dado instante, o que pode ocasionar discrepâncias e imprecisões principalmente em dias sem produção.
- Manutenção de tanque: Em duas ocasiões é possível observar que o cliente esvaziou o tanque para manutenção ou limpeza, carregando novamente no dia seguinte. Os sensores acusaram altos valores de consumo negativo quando o volume retornou ao tanque.

2.3.7 Avaliação dos métodos

Após a avaliação inicial sobre qual metodologia utilizar, os métodos deverão ser validados quanto a sua precisão frente a valores já conhecidos de demanda, assim trazendo uma medida de confiabilidade comparativa entre modelos que poderão ser semelhantes aos valores obtidos por meio da extrapolação.

Para isso, medidas de comparação do valor previsto com o dado histórico como o MAPE (*Mean Absolute Percentage Error*, erro médio absoluto percentual), RAE (*Relative Absolute Error*, erro médio absoluto) ou MSE (*Mean Square Error*, erro quadrático médio) podem ser usados para validar e comparar métodos (KALEKAR, 2004).

2.3.7.1 MAPE

A equação para o erro médio absoluto pode ser vista na Equação 11:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \frac{A_t - F_t}{A_t} \quad (11)$$

- Sendo A_t é o valor real no período t ;
- F_t é o valor previsto para o período t ;
- n é a quantidade de erros avaliados.

2.3.7.2 RAE

A equação para erro médio absoluto pode ser encontrada na Equação 12:

$$RAE = \frac{[\sum_{t=1}^n (F_t - A_t)^2]^{1/2}}{[\sum_{t=1}^n A_t^2]^{1/2}} \quad (12)$$

- Sendo A_t é o valor real no período t ;
- F_t é o valor previsto para o período t ;
- n é a quantidade de erros avaliados.

2.3.7.3 MSE

A equação para encontrar o erro médio quadrático é dada pela Equação 13:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (13)$$

- Sendo MSE o valor de erro obtido;
- n sendo o número de observações, para que seja calculada a média;
- Y_i o valor observado no período i ;
- \hat{Y}_i o valor previsto para o período i .

3 MATERIAL E MÉTODOS

Como base de dados para teste das metodologias propostas, foram coletadas as leituras de quantidades de produtos químicos disponíveis nos tanques de uma indústria durante o período de 10 meses. O produto em questão é um petroquímico em estado líquido utilizado para conferir flexibilidade à materiais poliméricos, com demanda de natureza relativamente constante ao longo do dia.

O tanque estudado possui medidor de nível com boa precisão e as leituras foram feitas respeitando os cuidados com a regularidade de horário, buscando sempre aferições em momentos em que o líquido não está sendo demandado, evitando assim imprecisões de leitura ocasionadas por agitação, borbulhamento ou dilatação devido a temperatura.

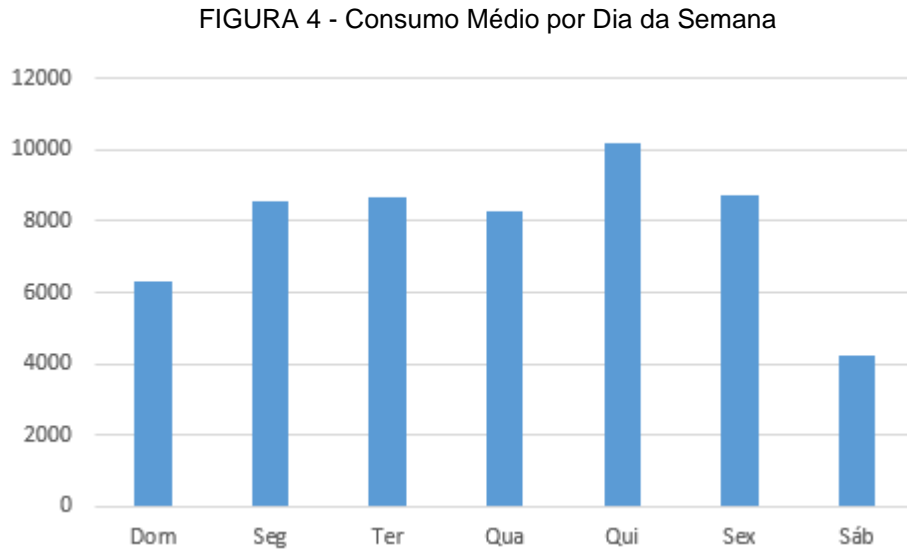
Serão utilizados dados reais de histórico de demanda de produtos, nos quais pode-se testar as ferramentas propostas neste trabalho quanto a sua precisão. Foram totalizadas 245 medições, uma vez ao dia, entre janeiro e outubro do ano de 2018. Como a leitura não era feita aos finais de semana, durante a segunda-feira, era consultado o nível correspondente ao sábado e ao domingo anterior de acordo com o histórico apresentado pelo EDI. As unidades correspondem à massa de líquido dentro do tanque, em libras.

Deve-se ressaltar que ao utilizar estes dados, cuidados serão tomados para que o fornecedor e o comprador sejam protegidos em questões de nome, valores e setor específico, destacando aspectos gerais que podem ser utilizados para compreensão do modelo de forma genérica.

3.1 ANÁLISE PRELIMINAR

Algumas informações foram percebidas durante a primeira análise preliminar da série de dados temporais. A primeira foi a presença de uma sazonalidade de acordo com o dia da semana em questão, que apresenta utilização do produto entre segunda e sexta-feira, enquanto se percebe utilização menor durante os sábados e domingos, conforme figura 2. Isto posto, começa a se tornar interessante a avaliação de métodos de previsão de demanda que levem em consideração a sazonalidade e

consigam atribuir índices para que ela também seja inserida nos valores futuros gerados pelo modelo.



Fonte: O autor (2019).

Outra constatação durante a análise preliminar foi a presença de valores discrepantes, os chamados *outliers*. Nessas leituras, o consumo pareceu ser muito negativo, ou seja, a quantidade de produto estocado no dia anterior era menor do que a do dia seguinte, sem que tenha ocorrido um abastecimento.

A explicação para o ocorrido é a de que houve manutenção do tanque nos dias em questão, em que foi necessária a remoção do conteúdo durante um período para que seja recolocado no dia seguinte. Tais manutenções ocorrem para troca das vedações (que sofrem ressecamento) e limpeza geral da tubulação entre tanque e maquinário subsequente.

Foi também localizada a presença de valores discrepantes mais suaves, que são caracterizados por valores negativos com menor valor em módulo e valores de alta demanda, ocasionados por imprecisões na aferição. Tais valores não foram utilizados como base para os métodos de previsão, visto que se trata de exceções as quais não poderiam ser previstas e não apresentam nenhuma regularidade relacionada ao plano de produção da empresa.

Na série de dados do estudo de caso, foi possível identificar medições discrepantes. Pode-se destacar três situações em que elas ocorreram:

3.2 APLICAÇÃO DE MÉTODOS DE PREVISÃO

Os métodos a seguir foram aplicados na série de dados de demanda, com intuito de prever quantas libras serão demandadas no horizonte de 15 dias. Os últimos 15 dias da série de dados não foi utilizada como entrada para os métodos, sendo estes reservados para criar uma estimativa de precisão dos valores encontrados e assim obter o MSE.

A definição de que não se usaria os 15 últimos dias surgiu após ser observado que os métodos que utilizavam um índice de amortização (amortização exponencial e Holt Winters) se beneficiavam muito, em termos de erro médio, ao se otimizar o índice de acordo com o erro avaliado ao longo de toda a série de dados. Além disso, este é um horizonte interessante para planejamento de entregas de caminhões tanque, pois é factível com o tempo de trânsito e de processamento interno dos pedidos de reabastecimento.

Os dados de demanda foram inseridos no *software* Microsoft Excel, onde as respectivas fórmulas e regras foram aplicadas de acordo com a seção 2.3. É válido lembrar que os valores utilizados foram corrigidos de acordo com as regras para tratamento de valores discrepantes descritas na seção anterior.

Foi utilizada a ferramenta Solver, do Microsoft Excel para determinar os valores de α no método de suavização exponencial e os valores dos parâmetros α , β e γ na utilização de Holt Winters. Foi calculado o erro de cada previsão, ou seja, a diferença entre o valor que o método forneceu e o real observado no período. A medida escolhida para a avaliação dos métodos do desse estudo de caso é a raiz do MSE, que utiliza a diferença entre o valor previsto e o valor histórico elevado ao quadrado. Esta medida se mostrou interessante pois seu componente exponencial destaca de maneira mais eficiente os valores mais discrepantes, os quais gerariam atrasos ou adiantamentos no abastecimento do cliente VMI. A metodologia que apresentar menor valor de erro MSE durante a comparação dos valores previstos será a utilizada durante o planejamento de demanda por caminhões do cliente abastecido.

Para aplicação das redes neurais artificiais, foi utilizado o software R, acrescido da biblioteca RSNNS (*Stuttgart Neural Network Simulator*), a qual dispõe de diversas implementações padrões para redes neurais e integra tais funcionalidades às aplicações já disponíveis no R. Um código foi criado para leitura

do histórico de demanda de um arquivo de texto, que contém as 245 leituras do nível de tanque, sendo que as 15 últimas leituras não foram disponibilizadas como dado de entrada, sendo estes utilizados apenas para avaliação posterior do método. A rede neural utilizada foi a MLP, que utiliza como correção dos pesos o chamado *back propagation*.

Foi testada a entrada de 3, 5, 7 e 10 valores anteriores para formulação de cada previsão, cada uma delas variando entre 1 a 50 neurônios na camada oculta da rede neural, resultando assim em 200 combinações de parâmetros de entrada, sendo a combinação que apresentou o melhor resultado a apresentada na seção de resultados a seguir. O número máximo de iterações para cada combinação foi limitado a 1000.

Segundo a Equação (13), o valor de erro real de cada previsão foi elevado ao quadrado e somado termo a termo a fim de que essa função se torne a função objetivo da otimização do Solver, a qual será minimizada. As células variáveis disponibilizadas para o solver foram os parâmetros de α na amortização exponencial e α , β e γ no caso de Holt Winters. Deve-se ressaltar que os últimos 15 valores de erro não foram utilizados como erro a ser minimizado, visto que estes valores serão usados apenas para avaliação posterior do método, e não como entrada de dados.

4 APRESENTAÇÃO DOS RESULTADOS

Os valores da raiz do erro MSE obtidos das metodologias, durante os últimos 15 dias reservados para avaliação dos métodos pode ser visto a seguir na TABELA 1, em que n representa o número de observações anteriores utilizadas no cálculo da previsão.

TABELA 1 – Erro Médio Quadrático dos métodos de previsão

Método	Raiz do MSE
Amortização exponencial Sem Sazonalidade	4.406
Amortização exponencial Com Sazonalidade	4.122
Média Móvel por Dia da Semana com $n = 3$	4.166
Média Móvel por Dia da Semana com $n = 5$	4.396
Média Móvel por Dia da Semana com $n = 7$	4.667
Média Móvel por Dia da Semana com $n = 10$	4.191
Decomposição clássica simples	3.833
Decomposição clássica com sazonalidade	4.060
Holt-Winters	6.612
Redes Neurais Artificiais	3.821

FONTE: O autor (2019).

Dentre as aplicações que demonstraram menor erro (raiz do MSE), pode-se identificar que as RNA se destacaram como a mais adequada para previsão da demanda futura, seguindo a premissa de que a sua melhor adequação aos 15 períodos reservados ao teste a qualificam como uma boa metodologia para os períodos seguintes.

A combinação de parâmetros da RNA que demonstrou melhor adequação foi com $n = 3$ e $k = 4$, ou seja, utilizando 3 previsões passadas para gerar uma futura, com 4 neurônios na camada oculta da rede neural. O número de iterações foi limitado a 1000.

É válido ressaltar que a decomposição clássica simples, que neste estudo apresentou o segundo menor raiz do MSE, se mostrou, para essa série dados, o método com resultado mais satisfatório que pode ser aplicado utilizando apenas funções simples dentro do Excel.

Um ponto importante de se comentar é a ineficiência demonstrada quanto à adequação do método de Holt-Winters à previsão proposta. Sua utilização apresentou o maior MSE. O parâmetro β foi otimizado para um número muito próximo a zero, enquanto o parâmetro γ a um número muito próximo de 1, o que levanta uma indagação quanto a necessidade da utilização de uma suavização de 3 parâmetros, visto que a suavização de 1 parâmetro (amortização exponencial) apresentou menor erro, tanto em sua aplicação com índice de sazonalidade quando na aplicação sem índice de sazonalidade.

Dentre os quatro casos testados para as médias móveis, não se pode identificar uma tendência clara de aumento ou diminuição de eficácia no que diz respeito à quantos valores passados (qual valor de n) utilizar para previsões, apenas que, entre as 4 combinações testadas, a utilização de $n = 3$ se mostrou mais satisfatório em termos de MSE.

5 CONSIDERAÇÕES FINAIS

Durante a revisão bibliográfica sobre os sistemas de fornecimento, pode-se perceber que a implantação do VMI pode ou não ser vantajosa para o cliente e para o fornecedor, cabendo a eles uma avaliação comparativa em horizontes de médio e longo prazo para determinação da viabilidade de tal parceria, visto que todas as metodologias de fornecimento apresentam suas vantagens e desvantagens situacionais.

Foram apresentados métodos matemáticos para previsão de demanda passíveis de serem utilizados em cenários de abastecimento VMI de produtos líquidos, bem como apresentadas metodologias de comparação entre eles. Os métodos também demonstram características próprias quanto a consideração de tendência, sazonalidade e complexidade, parâmetros relevantes durante a escolha de uma metodologia para aplicação em um planejamento de entregas.

Foi constatado, nas condições descritas no estudo de caso deste trabalho, que a metodologia mais indicada para a previsão do consumo para os próximos 15 dias da empresa em questão é a utilização das redes neurais artificiais MLP, por esta demonstrar menor erro médio quadrático.

É válido ressaltar que é interessante manter a avaliação de diversos métodos disponíveis, visto que com a entrada de novas observações, a metodologia que melhor se encaixe poderá ser outra.

O planejamento de datas de abastecimento pode ser beneficiado com a utilização de uma previsão de demanda bem estruturada, visto que o conhecimento prévio da data em que os volumes serão utilizados contribui para o aumento do nível de serviço do fornecimento, fortalecendo assim a relação entre cliente e fornecedor.

Os estudos realizados neste trabalho serão de grande valor para a empresa que disponibilizou os dados de demanda do cliente anônimo. A utilização do VMI poderá ser mais embasada em conceitos trazidos das bibliografias consultadas durante a realização deste trabalho, bem como as metodologias de previsão poderão ser aplicadas de forma semelhante para outros clientes que optem por disponibilizar a leitura de nível de tanque à empresa fornecedora.

6 REFERÊNCIAS

ARANGO, MARTÍN DARÍO; ADARME JAIME, W; CONTRERAS PORTILLA, P. **Vendor Managed Inventory (VMI) in micro, small and medium enterprises (MSMEs) - Plantain agricultural-chain**. Rev.fac.ing.univ. Antioquia, Medellín , n. 59, p. 181-192, June 2011 . Disponível em: <http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-62302011000300017&lng=en&nrm=iso>. Acesso em: 21 de jun 2018.

ARANGO, Martín DARÍO, ZAPATA, Julian ANDRÉS, & ADARME JAIMES, W. (2011). **Aplicación Del Modelo De Inventario Manejado Por El Vendedor En Una Empresa Del Sector Alimentario Colombiano**. Revista EIA, (15), 21-32. Disponível em: <http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1794-12372011000100003&lng=en&tlng=es> Acesso em: 21 de jun 2018

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2ª ed., Rio de Janeiro, LTC, 2011.

CLARK & HAMMOND: **Reengineering Channel Reordering Processes to Improve Total Supply-Chain Performance** - THEODORE H. CLARK AND JANICE H. HAMMOND. Product and Operations Management Vol. 6, No. 3, Fall 1997. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1937-5956.1997.tb00429.x>> Acesso em 30 de set 2018

CÓCCOLA, Mariana, MENDEZ, Carlos, DONDO, Rodolfo. **A Decomposition Framework For Distribution Of Fluid Products By A Vendor-Managed-Inventory Methodology**. 27th European Symposium on Computer Aided Process Engineering - ESCAPE 27, 2017. Disponível em: <<https://books.google.com.br/books?id=3xtYDgAAQBAJ&lpg=PA1387&dq=A%20decomposition%20framework%20for%20distribution%20of%20fluid%20products%20by%20a%20vendor-managed-inventory%20methodology&hl=pt-BR&pg=PA1387#v=onepage&q&f=false>> Acesso em: 19 de jul 2018

HUSH, DON R., HORNE, Bill G.: **Progress in Supervised Neural Networks** – IEEE Signal Processing Magazine, 10(1), 8–39, January 1993. Disponível em: < <https://ieeexplore.ieee.org/document/180705>> Acesso em 3 de nov de 2019

MENTZER, John T., DEWITT, William, KEEBLER, James S., MIN, Soohong, NANCY W. NIX, SMITH, Carlo D. AND ZACHARIA, G. - **Defining Supply Chain Management** – Journal of Business Logistics, Vol.22, No.2, 2001. Disponível em < http://www.aui.ma/personal/~A.Berrado/MGT5309/DEFINING%20SUPPLYCHAIN%20MANAGEMENT_Metzner%20et%20al.%202001.pdf> Acesso em 29 de jul 2018

LEE - **Information Distortion in a Supply Chain: The Bullwhip Effect**. HAU L. LEE, V. PADMANABHAN AND SEUNGJIN WHANG. Management Science, Vol. 43, No. 4, Frontier Research in Manufacturing and Logistics (Apr., 1997), pp. 546-558 Disponível em: <<http://www.jstor.org/stable/2634565>> Acesso em: 2 de out 2018

MATT WALKER, M. ERIC JOHNSON AND TOM DAVIS – **Vendor Managed Inventory In The Retail Supply Chain**, Journal of Business Logistics, Vol.20, No 1, 1999, Disponível em:

<<https://search.proquest.com/openview/72dade21256c0ed3f74696864111c220/1?pq-origsite=gscholar&cbl=36584>> Acesso em: 22 de jul de 2018

MONTEIRO, A., & BEZERRA, A. L. B. (2003). **Vantagem competitiva em logística empresarial baseada em tecnologia de informação**. VI SemeAd,-FEA/USP, São Paulo. Disponível em:

<https://www.researchgate.net/profile/Aluisio_Monteiro2/publication/228726364_Vantagem_Competitiva_em_Logistica_Empresarial_Baseada_em_Tecnologia_de_Informacao/links/55b6151208aec0e5f436d9e0/Vantagem-Competitiva-em-Logistica-Empresarial-Baseada-em-Tecnologia-de-Informacao.pdf> Acesso em 26 de set 2018

NELSON, NELSON (2003). **Aplicação De Algoritmos Genéticos Paralelos A Problemas De Grande Escala De Vmi – Vendor Managed Inventory**. XXXV Simpósio Brasileiro de Pesquisa Operacional, Natal.

Disponível em: <http://www.din.uem.br/sbpo/sbpo2003/pdf/arq0150.pdf> Acesso em 2 de nov de 2019

NOVAES, Antonio. **Logística e Gerenciamento da Cadeia de Distribuição**. Terceira edição. Elsevier, 2007.

ÖZENER, O. Ö.; ERGUN, Ö.; SAVELSBERGH, M. **Allocating cost of service to customers in inventory routing**. Operations Research, v. 61, n. 1, p. 112-125, 2013. Disponível em: <<http://dx.doi.org/10.1287/opre.1120.1130>> Acesso em 26 de set de 2018

PARSA - **Quantifying the Benefits Of Continuous Replenishment Program For Partner Evaluation**. PAYAM PARSA, MANUEL D. ROSSETTI, SHENGFAN ZHANG, EDWARD A. POHL – International Journal of Production Economics 187 (2017) 229-245. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0925527317300567>> Acesso em 1 de out 2018

S.M. DISNEY & D.R. TOWILL – **The Effect of Vendor Managed Inventory (VMI) Dynamics On The Bullwhip Effect In Supply Chains**. Int. J. Production Economics 85 (2003) 199-215. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0925527303001105>> Acesso em 1 de out 2018

SRINIVASAN RAGHUNATHAN AND ARTHUR B. YEH - **Beyond EDI: Impact of Continuous Replenishment Program (CRP) Between a Manufacturer and Its Retailers** - Information Systems Research, Vol. 12, No. 4 (December 2001), pp. 406-419. Disponível em: <<http://www.jstor.org/stable/23011460>> Acesso em 27 de jul 2018

TAVARES & LIMA, **Previsão, Reabastecimento e Planejamento Colaborativo (CPFR): Conceitos e Aplicações** - Flávio Luís Borges, Renato da Silva Lima - XIII SIMPEP - Bauru, SP, Brasil, 6 a 8 de Novembro de 2006 1. Disponível em: <http://www.simpep.feb.unesp.br/anais/anais_13/artigos/1065.pdf> Acesso em 29 de jul 2018

YE, Lexiang, Eamonn KEOGH, **Time Series Shapelets: A New Primitive for Data Mining**. Conference: Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Paris, 2009
Disponível em:<<http://www.cs.ucr.edu/~eamonn/shaplet.pdf>> Acesso em 3 de nov de 2019

ZHANG; PATUWO;HU, **Forecasting With Artificial Neural Networks: The state of the Art** - Guoqiang Zhang, B. Eddy Patuwo, Michael Y. Hu - International Journal of Forecasting 14 (1998) 35–62
Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0169207097000447>> Acesso em 2 de nov de 2019

7 APÊNDICE – RESULTADOS DAS PREVISÕES PARA OS ÚLTIMOS 15 DIAS

7.1 VALORES OBSERVADOS

Número da observação	Dia da semana	Data	Consumo Observado
231	Qua	10/17	10142
232	Qui	10/18	11238
233	Sex	10/19	4598
234	Sáb	10/20	140
235	Dom	10/21	8906
236	Seg	10/22	8975
237	Ter	10/23	6709
238	Qua	10/24	11952
239	Qui	10/25	8998
240	Sex	10/26	2255
241	Sáb	10/27	10861
242	Dom	10/28	15323
243	Seg	10/29	10584
244	Ter	10/30	6297
245	Qua	10/31	11257

Média: 8549

7.2 AMORTIZAÇÃO EXPONENCIAL SEM SAZONALIDADE

Amortização exponencial Sem Sazonalidade	
Previsto	Erro^2
7.179	8.781.316
6.593	21.575.389
6.365	3.121.608
6.276	37.648.459
6.241	7.101.408
6.228	7.548.014
6.222	236.813
6.220	32.852.248
6.220	7.719.999
6.219	15.714.876
6.219	21.547.443
6.219	82.882.265
6.219	19.053.122
6.219	6.083
6.219	25.381.426

Erro^2 Médio:	19.411.365
Raiz do erro médio:	4406

Sem Sazonalidade:	
Parâmetro alfa	0,610
Erro médio	26.418.488
Raiz do erro médio	5140

7.3 AMORTIZAÇÃO EXPONENCIAL COM SAZONALIDADE

Amortização exponencial Com Sazonalidade	
Previsto	Erro ²
8.693	2.100.923
10.696	293.511
9.030	19.645.972
4.338	17.623.830
6.470	5.935.813
8.719	65.506
8.768	4.237.638
8.254	13.678.467
10.169	1.371.403
8.596	40.209.778
4.135	45.244.941
6.174	83.711.204
8.330	5.080.502
8.386	4.364.384
7.904	11.245.862

Erro ² Médio:	16.987.316
Raiz do erro médio:	4122

Com Sazonalidade	
Parâmetro alfa	0,032
Erro médio	15.663.785
Raiz do erro médio	3958

7.4 MÉDIAS MÓVEIS:

Média Móvel por Dia da Semana							
n=3		n=5		n=7		n=10	
Previsto	Erro ²	Previsto	Erro ²	Previsto	Erro ²	Previsto	Erro ²
8.816	1.757.392	8.415	2.982.529	6.870	10.705.984	8.590	2.409.635
11.923	469.225	10.495	551.455	10.888	122.200	10.085	1.330.101
10.109	30.374.795	11.490	47.499.664	11.186	43.401.744	9.805	27.108.684
7.878	59.871.485	6.050	34.925.736	4.787	21.594.609	4.288	17.206.734
7.908	996.669	7.182	2.972.176	6.611	5.268.992	7.026	3.536.280
8.325	422.067	7.665	1.717.148	7.001	3.894.984	8.668	94.249
6.810	10.268	8.724	4.060.225	9.232	6.367.692	8.785	4.310.606
9.961	3.964.966	8.883	9.421.216	7.731	17.819.253	8.085	14.952.374
10.145	1.315.609	11.355	5.556.769	10.168	1.368.041	10.478	2.190.015
10.523	68.367.174	11.627	87.841.882	11.178	79.614.830	9.834	57.437.603
5.283	31.111.605	6.587	18.267.418	5.094	33.258.289	4.543	39.913.207
7.702	58.081.335	7.810	56.451.180	6.402	79.585.333	6.921	70.594.444
8.820	3.112.480	7.960	6.886.846	7.455	9.791.152	8.218	5.596.536
6.704	165.739	8.409	4.461.389	8.277	3.920.642	8.808	6.304.217
11.824	321.531	8.749	6.288.459	8.097	9.988.567	8.029	10.422.005

Erro ² Médio:	17.356.156	Erro ² Médio:	19.325.606	Erro ² Médio:	21.780.154	Erro ² Médio:	17.560.446
Raiz do erro médio:	4166	Raiz do erro médio:	4396	Raiz do erro médio:	4667	Raiz do erro médio:	4191

7.5 DECOMPOSIÇÃO CLÁSSICA DA SÉRIE TEMPORAL:

Decomposição clássica			
Sem Sazonalidade		Com Sazonalidade	
Previsto	Erro ²	Previsto	Erro ²
8.154	3.951.504	8.556	2513824
8.159	9.482.319	10.619	383314
8.163	12.710.394	9.040	19731385
8.168	64.443.413	4.378	17962047
8.172	538.511	6.582	5403126
8.177	637.333	8.939	1297
8.181	2.167.284	9.057	5513750
8.186	14.185.231	8.590	11305998
8.190	652.585	10.660	2761875
8.195	35.279.731	9.075	46511001
8.199	7.085.308	4.395	41808429
8.204	50.684.756	6.607	75970144
8.208	5.644.527	8.973	2593918
8.213	3.669.831	9.092	7812146
8.217	9.240.495	8.623	6939928

Erro ² Médio:	14.691.548	Erro ² Médio:	16.480.812
Raiz do erro médio:	3833	Raiz do erro médio:	4060

Índices	
Dia da semana	Normalizado
Dom	0,805
Seg	1,093
Ter	1,107
Qua	1,049
Qui	1,302
Sex	1,107
Sáb	0,536
Soma:	7

Parâmetros	
N	230
a	4,50148
b	7114,32013

7.6 HOLT-WINTERS:

Holt-Winters	
Previsto	Erro ²
20.014	97.456.646
14.535	10.873.479
14.514	98.325.318
5.695	30.856.440
7.615	1.667.057
7.994	962.815
6.219	240.064
20.014	64.997.986
14.536	30.664.822
14.514	150.283.059
5.695	26.688.678
7.615	59.414.807
7.994	6.709.050
6.219	6.072
20.014	76.689.470

Erro ² Médio:	43.722.384
Raiz do erro médio:	6612

Alfa	0,120
Beta	0,000
Gama	1,000

Comp. de nível	7334
Comp. de tendência	41,69

7.7 REDES NEURAIS

7.7.1 CÓDIGO UTILIZADO

```

library('RSNNS')
dados<-read.table('C:\\Users\\Victor\\Desktop\\dados_consumo.txt')
dados<-dados$V1

#k será quantas vezes farei essa sequencia
result<-NULL
for (k in 1:50){
  for (j in c(3,5,7,10)){

    M<-NULL
    for (i in 1:(length(dados)-j)){
      M<-rbind(M,dados[i:(j+i)])
    }

    train<-M[1:(nrow(M)-15),]
    test<-M[(nrow(M)-15+1):nrow(M),]

    set.seed(1)
    rede<-mlp(x=train[,1:j],y=train[,j+1],size=k,maxit=10000,outputActFunc ="Act_Identity")
    previsao<-predict(rede,test[,1:j])
    erro<-sqrt(mean((previsao-test[,j+1])^2))
    result<-rbind(result,c(j,k,erro))
  }
}

minimo<-result[which.min(result[,3]),]
# precisa refazer a matriz M e os conjuntos de treinamento e teste antes de rodar a rede final
M<-NULL
for (i in 1:(length(dados)-minimo[1])){
  M<-rbind(M,dados[i:(minimo[1]+i)])
}

train<-M[1:(nrow(M)-15),]
test<-M[(nrow(M)-15+1):nrow(M),]

set.seed(1)

```

```

rede<-
mlp(x=train[,1:minimo[1]],y=train[,minimo[1]+1],size=minimo[2],maxit=10000,outputActFunc
="Act_Identity")
previsao<-predict(rede,test[,1:minimo[1]])

plot(1:15,test[,minimo[1]+1],pch=16,type='l')
points(1:15,previsao,col='red',pch=16)
lines(1:15,previsao,col='red',pch=16)

for (i in 1:10){
  j=j+1
  cat(i,'\n')
}
}

```

7.7.2 Erro obtido em cada combinação de n e k

Sendo n , que varia entre 3, 5, 7 e 10 a quantidade de leituras anteriores levadas em consideração para a previsão e k , que varia entre 1 e 50 a quantidade de neurônios na camada oculta da rede neural. Os valores destacados em verde correspondem aos 10% melhores resultados obtidos.

	n	k	Erro Obtido
1	3	1	4.709.435.000
2	5	1	3.999.752.000
3	7	1	4.831.032.000
4	10	1	4.582.518.000
5	3	2	4.495.052.000
6	5	2	4.007.049.000
7	7	2	3.825.879.000
8	10	2	4.012.078.000
9	3	3	3.987.322.000
10	5	3	5.285.522.000
11	7	3	4.231.795.000
12	10	3	4.642.412.000
13	3	4	3.821.472.000
14	5	4	3.864.875.000
15	7	4	4.359.164.000
16	10	4	4.336.730.000

	n	k	Erro Obtido
68	10	17	7.122.387.000
69	3	18	8.506.221.000
70	5	18	56.452.790.000
71	7	18	4.641.799.000
72	10	18	Rede não convergiu
73	3	19	4.656.189.000
74	5	19	32.244.630.000
75	7	19	5.931.036.000
76	10	19	Rede não convergiu
77	3	20	5.582.313.000
78	5	20	4.002.567.000
79	7	20	217.934.500.000
80	10	20	Rede não convergiu
81	3	21	7.056.720.000
82	5	21	Rede não convergiu
83	7	21	8.566.260.000

	n	k	Erro Obtido
133	3	34	Rede não convergiu
134	5	34	Rede não convergiu
135	7	34	Rede não convergiu
136	10	34	Rede não convergiu
137	3	35	Rede não convergiu
138	5	35	Rede não convergiu
139	7	35	Rede não convergiu
140	10	35	Rede não convergiu
141	3	36	Rede não convergiu
142	5	36	Rede não convergiu
143	7	36	Rede não convergiu
144	10	36	Rede não convergiu
145	3	37	Rede não convergiu
146	5	37	Rede não convergiu
147	7	37	Rede não convergiu
148	10	37	Rede não convergiu

17	3	5	3.898.974.000
18	5	5	3.929.338.000
19	7	5	4.157.801.000
20	10	5	3.880.600.000
21	3	6	3.911.080.000
22	5	6	4.040.056.000
23	7	6	4.143.030.000
24	10	6	5.241.433.000
25	3	7	3.961.566.000
26	5	7	8.450.495.000
27	7	7	4.223.746.000
28	10	7	6.488.335.000
29	3	8	4.887.743.000
30	5	8	3.911.248.000
31	7	8	7.091.599.000
32	10	8	3.912.492.000
33	3	9	5.068.647.000
34	5	9	3.828.753.000
35	7	9	4.541.414.000
36	10	9	6.839.579.000
37	3	10	3.963.473.000
38	5	10	4.171.156.000
39	7	10	4.953.186.000
40	10	10	5.588.900.000
41	3	11	11.605.430.000
42	5	11	4.231.052.000
43	7	11	4.266.966.000
44	10	11	7.554.894.000
45	3	12	5.777.590.000
46	5	12	5.515.530.000
47	7	12	7.688.231.000
48	10	12	10.637.300.000
49	3	13	6.586.590.000
50	5	13	5.990.386.000
51	7	13	4.881.464.000
52	10	13	4.236.655.000
53	3	14	4.734.277.000
54	5	14	Rede não convergiu
55	7	14	4.887.958.000
56	10	14	Rede não convergiu
57	3	15	15.011.750.000
58	5	15	5.160.373.000
59	7	15	4.679.152.000
60	10	15	5.550.800.000
61	3	16	8.461.180.000

84	10	21	Rede não convergiu
85	3	22	6.920.088.000
86	5	22	95.480.880.000
87	7	22	3.885.656.000
88	10	22	Rede não convergiu
89	3	23	9.159.695.000
90	5	23	Rede não convergiu
91	7	23	6.899.213.000
92	10	23	Rede não convergiu
93	3	24	16.117.530.000
94	5	24	Rede não convergiu
95	7	24	8.797.976.000
96	10	24	Rede não convergiu
97	3	25	827.757.800.000
98	5	25	Rede não convergiu
99	7	25	93.327.520.000
100	10	25	Rede não convergiu
101	3	26	14.463.040.000
102	5	26	Rede não convergiu
103	7	26	6.326.835.000
104	10	26	4.750.997.000
105	3	27	Rede não convergiu
106	5	27	117.259.200.000
107	7	27	3.840.393.000
108	10	27	Rede não convergiu
109	3	28	Rede não convergiu
110	5	28	Rede não convergiu
111	7	28	Rede não convergiu
112	10	28	Rede não convergiu
113	3	29	7.069.851.000
114	5	29	Rede não convergiu
115	7	29	Rede não convergiu
116	10	29	Rede não convergiu
117	3	30	8.397.158.000.000
118	5	30	Rede não convergiu
119	7	30	Rede não convergiu
120	10	30	Rede não convergiu
121	3	31	18.093.970.000
122	5	31	Rede não convergiu
123	7	31	Rede não convergiu
124	10	31	Rede não convergiu
125	3	32	Rede não convergiu
126	5	32	Rede não convergiu
127	7	32	Rede não convergiu
128	10	32	Rede não convergiu

149	3	38	Rede não convergiu
150	5	38	Rede não convergiu
151	7	38	Rede não convergiu
152	10	38	Rede não convergiu
153	3	39	Rede não convergiu
154	5	39	Rede não convergiu
155	7	39	Rede não convergiu
156	10	39	Rede não convergiu
157	3	40	Rede não convergiu
158	5	40	Rede não convergiu
159	7	40	Rede não convergiu
160	10	40	Rede não convergiu
161	3	41	Rede não convergiu
162	5	41	Rede não convergiu
163	7	41	Rede não convergiu
164	10	41	Rede não convergiu
165	3	42	Rede não convergiu
166	5	42	Rede não convergiu
167	7	42	Rede não convergiu
168	10	42	Rede não convergiu
169	3	43	Rede não convergiu
170	5	43	Rede não convergiu
171	7	43	Rede não convergiu
172	10	43	Rede não convergiu
173	3	44	Rede não convergiu
174	5	44	Rede não convergiu
175	7	44	Rede não convergiu
176	10	44	Rede não convergiu
177	3	45	Rede não convergiu
178	5	45	Rede não convergiu
179	7	45	Rede não convergiu
180	10	45	Rede não convergiu
181	3	46	Rede não convergiu
182	5	46	Rede não convergiu
183	7	46	Rede não convergiu
184	10	46	Rede não convergiu
185	3	47	Rede não convergiu
186	5	47	Rede não convergiu
187	7	47	Rede não convergiu
188	10	47	Rede não convergiu
189	3	48	Rede não convergiu
190	5	48	Rede não convergiu
191	7	48	Rede não convergiu
192	10	48	Rede não convergiu
193	3	49	Rede não convergiu

62	5	16	12.586.170.000
63	7	16	10.181.140.000
64	10	16	20.587.660.000
65	3	17	18.240.450.000
66	5	17	9.593.135.000
67	7	17	8,66E+22

129	3	33	Rede não convergiu
130	5	33	Rede não convergiu
131	7	33	Rede não convergiu
132	10	33	Rede não convergiu

194	5	49	Rede não convergiu
195	7	49	Rede não convergiu
196	10	49	Rede não convergiu
197	3	50	Rede não convergiu
198	5	50	Rede não convergiu
199	7	50	Rede não convergiu
200	10	50	Rede não convergiu

7.7.3 Erro obtido na previsão

Redes Neurais	
Previsto	Erro^2
8.469	2.798.420
8.469	7.666.519
8.469	14.985.818
8.469	69.374.773
8.469	190.836
9.481	255.582
8.469	3.098.135
8.469	12.130.230
8.469	279.680
8.469	38.615.685
8.469	5.720.937
8.469	46.975.232
8.469	4.472.582
8.469	4.718.244
8.469	7.772.096

Erro^2 Médio:	14.603.651
Raiz do erro médio:	3821

7.8 DADOS DE DEMANDA

Referentes a 1º de março a 31 de outubro de 2018

Dia	Data	Leitura	Consumo
Qui	1/3/18	109.151	5.193
Sex	2/3/18	103.958	14.520
Sáb	3/3/18	89.438	2.935
Dom	4/3/18	86.503	1.939
Seg	5/3/18	84.564	11.174
Ter	6/3/18	118.390	7.549
Qua	7/3/18	110.841	6.726
Qui	8/3/18	104.115	9.507
Sex	9/3/18	94.608	1.590
Sáb	10/3/18	93.018	546
Dom	11/3/18	92.472	2.639
Seg	12/3/18	89.833	12.160
Ter	13/3/18	122.673	6.374
Qua	14/3/18	116.299	18.707
Qui	15/3/18	97.592	10.914
Sex	16/3/18	86.678	2.001
Sáb	17/3/18	84.677	9.540
Dom	18/3/18	75.137	5.169
Seg	19/3/18	69.968	7.248
Ter	20/3/18	62.720	3.281
Qua	21/3/18	104.439	12.882
Qui	22/3/18	91.557	11.170
Sex	23/3/18	80.387	16.602
Sáb	24/3/18	63.785	2.218
Dom	25/3/18	61.567	3.650
Seg	26/3/18	57.917	5.011
Ter	27/3/18	97.906	9.614
Qua	28/3/18	88.292	7.809
Qui	29/3/18	80.483	7.554
Sex	30/3/18	67.437	7.712
Sáb	31/3/18	112.437	387
Dom	1/4/18	112.050	498
Seg	2/4/18	111.552	3.699
Ter	3/4/18	107.853	12.402
Qua	4/4/18	95.451	12.882

Dia	Data	Leitura	Consumo
Qui	5/4/18	117.690	10.914
Sex	6/4/18	132.114	10.644
Sáb	7/4/18	121.470	6.826
Dom	8/4/18	114.644	7.102
Seg	9/4/18	107.542	9.247
Ter	10/4/18	98.295	5.844
Qua	11/4/18	92.451	6.434
Qui	12/4/18	86.017	14.135
Sex	13/4/18	116.882	9.986
Sáb	14/4/18	106.896	1.066
Dom	15/4/18	105.830	2.045
Seg	16/4/18	103.785	7.291
Ter	17/4/18	96.494	10.566
Qua	18/4/18	85.928	12.405
Qui	19/4/18	118.523	4.932
Sex	20/4/18	113.591	5.554
Sáb	21/4/18	108.037	8.309
Dom	22/4/18	98.728	3.066
Seg	23/4/18	95.662	3.111
Ter	24/4/18	92.551	7.357
Qua	25/4/18	130.194	8.531
Qui	26/4/18	121.663	7.985
Sex	27/4/18	99.186	6.587
Sáb	28/4/18	108.644	7.081
Dom	29/4/18	101.563	7.417
Seg	30/4/18	94.146	14.766
Ter	1/5/18	79.380	7.088
Qua	2/5/18	117.292	5.608
Qui	3/5/18	114.684	5.825
Sex	4/5/18	109.859	14.856
Sáb	5/5/18	85.431	756
Dom	6/5/18	86.819	5.842
Seg	7/5/18	79.903	9.845
Ter	8/5/18	70.058	4.527
Qua	9/5/18	65.531	12.567

Dia	Data	Leitura	Consumo
Qui	10/5/18	97.964	14.763
Sex	11/5/18	83.201	6.761
Sáb	12/5/18	76.440	31
Dom	13/5/18	76.409	4.125
Seg	14/5/18	72.284	4.499
Ter	15/5/18	67.785	11.340
Qua	16/5/18	101.445	10.471
Qui	17/5/18	90.974	14.608
Sex	18/5/18	76.366	7.936
Sáb	19/5/18	68.430	2.897
Dom	20/5/18	65.533	4.470
Seg	21/5/18	61.063	9.851
Ter	22/5/18	96.212	5.486
Qua	23/5/18	90.726	4.925
Qui	24/5/18	85.996	9.086
Sex	25/5/18	76.910	9.535
Sáb	26/5/18	112.375	2.695
Dom	27/5/18	109.680	6.458
Seg	28/5/18	103.222	7.492
Ter	29/5/18	95.730	7.473
Qua	30/5/18	88.257	11.345
Qui	31/5/18	121.912	4.189
Sex	1/6/18	117.723	826
Sáb	2/6/18	116.897	2.248
Dom	3/6/18	114.649	2.183
Seg	4/6/18	112.466	7.130
Ter	5/6/18	105.336	13.085
Qua	6/6/18	137.251	4.867
Qui	7/6/18	132.384	13.848
Sex	8/6/18	118.536	9.204
Sáb	9/6/18	109.332	1.842
Dom	10/6/18	107.490	9.889
Seg	11/6/18	97.601	10.546
Ter	12/6/18	87.055	14.730
Qua	13/6/18	72.325	1.492

Dia	Data	Leitura	Consumo
Qui	14/6/18	70.833	8.799
Sex	15/6/18	107.034	6.641
Sáb	16/6/18	100.393	2.283
Dom	17/6/18	98.110	8.164
Seg	18/6/18	89.946	9.382
Ter	19/6/18	80.564	6.134
Qua	20/6/18	74.430	7.524
Qui	21/6/18	66.906	18.358
Sex	22/6/18	93.548	8.650
Sáb	23/6/18	84.898	5.201
Dom	24/6/18	79.697	8.584
Seg	25/6/18	71.113	9.578
Ter	26/6/18	61.535	15.091
Qua	27/6/18	91.444	837
Qui	28/6/18	90.607	11.893
Sex	29/6/18	78.714	11.872
Sáb	30/6/18	66.842	2.283
Dom	1/7/18	67.468	15.372
Seg	2/7/18	52.096	4.944
Ter	3/7/18	47.152	8.793
Qua	4/7/18	83.359	1.492
Qui	5/7/18	83.600	9.616
Sex	6/7/18	73.984	3.773
Sáb	7/7/18	115.211	12.126
Dom	8/7/18	103.085	12.065
Seg	9/7/18	91.020	2.672
Ter	10/7/18	88.348	421
Qua	11/7/18	87.927	6.903
Qui	12/7/18	81.024	12.456
Sex	13/7/18	113.568	5.003
Sáb	14/7/18	108.565	12.626
Dom	15/7/18	95.939	10.234
Seg	16/7/18	85.705	5.731
Ter	17/7/18	65.232	10.943
Qua	18/7/18	54.289	3.402

Dia	Data	Leitura	Consumo
Qui	19/7/18	50.887	3.088
Sex	20/7/18	92.799	6.111
Sáb	21/7/18	86.688	340
Dom	22/7/18	86.348	5.906
Seg	23/7/18	80.442	10.311
Ter	24/7/18	70.131	3.209
Qua	25/7/18	66.922	8.504
Qui	26/7/18	103.418	10.646
Sex	27/7/18	92.772	7.863
Sáb	28/7/18	84.909	4.037
Dom	29/7/18	80.872	3.603
Seg	30/7/18	77.269	16.794
Ter	31/7/18	105.475	4.520
Qua	1/8/18	100.955	11.006
Qui	2/8/18	89.949	6.153
Sex	3/8/18	83.796	5.510
Sáb	4/8/18	78.286	3.305
Dom	5/8/18	74.981	1.341
Seg	6/8/18	73.640	5.063
Ter	7/8/18	113.577	14.018
Qua	8/8/18	99.559	13.635
Qui	9/8/18	85.924	6.153
Sex	10/8/18	87.949	9.513
Sáb	11/8/18	67.617	1.736
Dom	12/8/18	65.881	8.071
Seg	13/8/18	57.810	13.165
Ter	14/8/18	89.645	8.559
Qua	15/8/18	81.086	8.650
Qui	16/8/18	72.436	8.119
Sex	17/8/18	64.317	3.246
Sáb	18/8/18	106.071	757
Dom	19/8/18	105.314	3.375
Seg	20/8/18	101.939	14.437
Ter	21/8/18	87.502	6.739
Qua	22/8/18	80.763	15.522
Qui	23/8/18	110.241	10.356

Dia	Data	Leitura	Consumo
Sex	24/8/18	99.885	6.985
Sáb	25/8/18	92.900	6.879
Dom	26/8/18	86.021	12.535
Seg	27/8/18	73.486	10.068
Ter	28/8/18	63.418	7.927
Qua	29/8/18	100.491	845
Qui	30/8/18	99.646	15.934
Sex	31/8/18	83.712	11.244
Sáb	1/9/18	72.468	2.638
Dom	2/9/18	69.830	8.071
Seg	3/9/18	70.499	3.827
Ter	4/9/18	66.672	15.920
Qua	5/9/18	95.752	5.170
Qui	6/9/18	90.582	7.808
Sex	7/9/18	82.774	9.608
Sáb	8/9/18	73.166	622
Dom	9/9/18	72.544	2.293
Seg	10/9/18	70.251	6.860
Ter	11/9/18	108.391	5.087
Qua	12/9/18	103.304	6.077
Qui	13/9/18	97.227	6.196
Sex	14/9/18	136.031	10.803
Sáb	15/9/18	125.228	3.364
Dom	16/9/18	121.864	4.044
Seg	17/9/18	117.820	6.189
Ter	18/9/18	111.631	10.298
Qua	19/9/18	101.333	9.549
Qui	20/9/18	91.784	10.512
Sex	21/9/18	81.272	16.319
Sáb	22/9/18	64.953	3.252
Dom	23/9/18	61.701	8.143
Seg	24/9/18	53.558	7.158
Ter	25/9/18	91.400	12.891
Qua	26/9/18	78.509	5.383
Qui	27/9/18	73.126	17.257
Sex	28/9/18	100.869	8.867

Dia	Data	Leitura	Consumo
Sáb	29/9/18	92.002	15.661
Dom	30/9/18	76.341	8.525
Seg	1/10/18	67.816	6.842
Ter	2/10/18	60.974	7.129
Qua	3/10/18	53.845	4.371
Qui	4/10/18	94.474	5.025
Sex	5/10/18	89.449	7.823
Sáb	6/10/18	81.626	1.161
Dom	7/10/18	80.465	6.538
Seg	8/10/18	73.927	9.630
Ter	9/10/18	64.297	7.083
Qua	10/10/18	57.214	16.695
Qui	11/10/18	85.519	13.487
Sex	12/10/18	72.032	13.638
Sáb	13/10/18	103.394	6.811
Dom	14/10/18	96.583	8.660
Seg	15/10/18	87.923	8.504
Ter	16/10/18	79.419	6.219
Qua	17/10/18	73.200	10.142
Qui	18/10/18	108.058	11.238
Sex	19/10/18	96.820	4.598
Sáb	20/10/18	97.061	140
Dom	21/10/18	96.921	8.906
Seg	22/10/18	88.015	8.975
Ter	23/10/18	79.040	6.709
Qua	24/10/18	117.331	11.952
Qui	25/10/18	105.379	8.998
Sex	26/10/18	96.381	2.255
Sáb	27/10/18	94.126	10.861
Dom	28/10/18	83.265	15.323
Seg	29/10/18	67.942	10.584
Ter	30/10/18	57.358	6.297
Qua	31/10/18	96.061	11.257