

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
PROGRAMA DE MESTRADO EM ENGENHARIA DE PRODUÇÃO E SISTEMAS

Aplicação de Redes Neurais Artificiais na Previsão de Demanda de Peças de Reposição de Veículos Automotores

Paulo Henrique Borba Florêncio

2016

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA PREVISÃO DE DEMANDA DE PEÇAS DE REPOSIÇÃO DE VEÍCULOS AUTOMOTORES

Paulo Henrique Borba Florêncio

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica de Goiás, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: Sibélius Lellis Vieira, Dr.

Goiânia,
Março de 2016

Dissertação financiada pela Fundação de Amparo à Pesquisa no Estado de Goiás - FAPEG, conforme: Chamada Pública Nº 003/2014 - Utilização de Redes Neurais Artificiais na Previsão de Demanda de Peças de Reposição de Veículos Automotores

F632a Florêncio, Paulo Henrique Borba
Aplicação de redes neurais artificiais na previsão
de demanda de peças de reposição de veículos automotores
[manuscrito] / Paulo Henrique Borba Florêncio.-- 2016.
86 f.; il.; 30 cm

Texto em português com resumo em inglês.
Dissertação (mestrado) -- Pontifícia Universidade
Católica de Goiás, Programa de Pós-Graduação STRICTO
SENSU em Engenharia de Produção e Sistemas, Goiânia,
2016

Inclui referências

1. Redes neurais (Computação). 2. Inteligência artificial.
3. Veículos a motor - Manutenção e reparos. 4. Veículos
a motor. 5. Oferta e procura. I.Vieira, Sibelius Lellis.
II.Pontifícia Universidade Católica de Goiás. III.
Título.

CDU: 004.032.26(043)

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREVISÃO DE DEMANDA DE PEÇAS DE REPOSIÇÃO DE VEÍCULOS AUTOMOTORES

Paulo Henrique Borba Florêncio

Esta Dissertação julgada adequada para obtenção do título de Mestre em Engenharia de Produção e Sistemas e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica de Goiás em março de 2016.

Prof. Ricardo Luiz Machado, Dr.
Coordenador do Programa de Pós-Graduação
em Engenharia de Produção e Sistemas

Banca Examinadora:

Prof. Sibélius Lellis Vieira, Dr.
Orientador

Prof. José Elmo de Menezes (PUCGO), Dr.

Prof. Antônio César Baleeiro Alves (Externo), Dr.

Goiânia - Goiás,
Março de 2016

Dissertação financiada pela Fundação de Amparo à Pesquisa no Estado de Goiás - FAPEG, conforme: Chamada Pública Nº 003/2014 - Utilização de Redes Neurais Artificiais na Previsão de Demanda de Peças de Reposição de Veículos Automotores

À Deus, pelo dom da vida.

Ofereço

À minha esposa, Fabrícia, pelo amor e carinho dedicados, aos meus filhos, Raphael e Isabelly pelas horas que deixamos de estar juntos e a minha mãe Elizabeth pelo apoio nas horas certas.

Dedico.

AGRADECIMENTOS

Agradeço Àquele que me presenteou com o bem mais precioso que poderia receber um dia, a vida, e com ela a capacidade para pensar, amar e lutar pela conquista dos ideais. Muitas foram as lutas, maiores as vitórias, e isso porque o Senhor Se fez sempre presente, transformando a fraqueza em força e a derrota em vitória. Reconheço que o tempo todo o Senhor esteve presente com terno amor e que sem a Sua misericordiosa graça e intervenção nada disso seria possível.

Aos meus familiares, que jamais deixaram de acreditar em mim, principalmente meu Pai (*in memorian*) e minha Mãe, que me ensinaram que uma pessoa deve ser honesta e ter fé. A minha esposa, meus filhos e minhas irmãs pelos momentos de imensa alegria vividos em família. Sem o amor e apoio de vocês eu jamais teria chegado até aqui.

Aos meus amigos de laboratório, Agenor, Rafael e Jônathas que foram peças fundamentais no dia-a-dia do desenvolvimento deste trabalho auxiliando nas pesquisas em cada etapa de desenvolvimento.

Ao meu orientador, Prof. Dr. Sibelius Lellis Vieira, pelas excelentes contribuições e direcionamento que deu ao trabalho, além dos rápidos retornos e revisões, sem os quais seria impossível desenvolver este estudo.

Aos demais professores e funcionários do Mestrado em Engenharia da Produção e Sistemas da PUC/GO pelos conhecimentos compartilhados nas disciplinas ministradas e aos colegas de curso.

Agradeço também a Fundação de Amparo à Pesquisa de Goiás – FAPEG, pelos recursos financeiros e bolsas que foram disponibilizados e que muito auxiliaram na condução da pesquisa.

RESUMO

As constantes mudanças no cenário nacional de venda de automóveis trouxeram um fator a mais na busca do gerenciamento dos estoques de peças de reposição: a necessidade de diminuir o valor investido em estoques e evitar a obsolescência. Com esse propósito, este trabalho tem por objetivo avaliar o desempenho de Redes Neurais Artificiais na previsão de demanda de peças de reposição de veículos automotores identificando, dentre as redes estudadas, quais se adaptam melhor a cada modelo de evolução de consumo e como se aplica em cada caso. Outrossim, propõe a utilização de um método de avaliação e monitoramento dos modelos selecionados através da análise dos erros médios quadráticos da previsão. A determinação de métodos preditivos com maior grau de precisão, constitui-se em etapa fundamental do processo de gerenciamento de estoques. Se a previsão apresentar uma baixa acurácia, pode-se gerar excesso ou falta de estoques e esse excesso, se não tratado adequadamente, pode culminar em obsolescência e gerar custos desnecessários. Para alcançar o objetivo proposto, buscou-se, em primeiro lugar, o estudo dos principais aspectos teóricos relacionados ao processo de gestão de estoques e aos métodos de previsão de demanda. Posteriormente, segue o processo de seleção de duas redes neurais artificiais, Rede de Elman e Rede TDNN. Para certificar a acurácia das demandas, foram utilizados quatro itens que se diferem pelo tipo de gráfico de evolução de consumo, buscando itens com consumo constante, crescente, decrescente e itens com quantidades menores de períodos observados. Os resultados obtidos, mediante a utilização da metodologia proposta, mostraram que as Redes Neurais possuem as características necessárias para sua aplicação com um grau de acurácia mais elevado.

Palavras-chave: previsão de demanda, redes neurais, séries temporais.

ABSTRACT

The constant changes on the national car sales scenario brought one more factor in the search of management of spare parts inventory; the need to reduce the amount invested in stocks and avoid obsolescence. For this purpose, the work aims to evaluate the performance of Artificial Neural Networks in predicting demand for vehicles of engine parts identifying, among the studied networks, which are best suited to each evolution of consumer model and how it applies in each case. Furthermore, it proposes the use of a method of assessment and monitoring of selected models by analyzing the root mean square errors of prediction. The determination of predictive methods with a higher degree of accuracy, is a critical step in the process of inventory management. If the forecast has a low accuracy can generate excess or lack of inventory and this excess, if not properly treated, it can lead to the obsolescence and generate unnecessary costs. To achieve the objective, sought first, the study of the major theoretical aspects of the methods of inventory management processes and demand forecasting. Later, after the selection process two artificial neural networks, Elman network and TDNN Network. To ensure the accuracy of the demands were used four items that differ by the type of evolution of consumption chart, looking for items with constant consumption, increasing, decreasing and items with smaller amounts of observed periods. The results obtained through the use of the proposed methodology, showed that neural networks have the necessary characteristics for your application with a higher degree of accuracy.

Keywords: demand forecasting, neural networks, time series.

LISTA DE FIGURAS

Figura 1 - Custo Total do Estoque.....	17
Figura 2 - Métodos de Previsão de Demanda.....	20
Figura 3 - Estrutura Geral do Neurônio Biológico	25
Figura 4 - Neurônio Artificial.....	26
Figura 5 – Exemplo de Arquitetura de Rede (Camada única e Multi Camada).....	27
Figura 6 – Representação Gráfica de Diversas Funções de Ativação	29
Figura 7 – Mecanismo de aprendizado supervisionado.....	31
Figura 8 - Rede de Elman com uma camada oculta aplicada ao problema de predição de séries temporais.	35
Figura 9 – Topologia de Uma Rede TDNN	37
Figura 10 – Gráfico com os dados de consumo de quatro itens do estoque.....	47
Figura 11 - Autocorrelação e autocorrelação parcial do anteparo dianteiro.....	49
Figura 12 - Autocorrelação e autocorrelação parcial da presilha do para choque.....	49
Figura 13 - Autocorrelação e autocorrelação parcial do tapete standart	50
Figura 14 - Autocorrelação e autocorrelação parcial do para choque traseiro	51
Figura 15 - Rede de Elman	53
Figura 16 - Performance do MSE na rede de Elman.....	54
Figura 17 – Previsões encontradas pela rede de Elman.....	56
Figura 18 - Rede TDNN	57
Figura 19 - Performance do MSE na rede TDNN	58
Figura 20- Previsões encontradas pela rede TDNN	60
Figura 21 - Comparativo das previsões encontradas pela rede de Elman e TDNN	62
Figura 22 - Comparativo das redes de Elman e TDNN após retirada de períodos de inatividade	64

LISTA DE TABELAS

Tabela 1 - Principais Características dos Métodos Quantitativos de Previsão de Demanda.....	22
Tabela 2 - Trabalhos Relacionados - Previsão de Séries Temporais Mediante RNA	40
Tabela 3- Medidas de erro de previsão dos modelos da rede de Elman.....	55
Tabela 4 - Medidas de Erro de Previsão dos Modelos da Rede TDNN	59
Tabela 5 - Medidas de Erro de Previsão dos Modelos da Rede de Elman e TDNN	61
Tabela 6- Avaliação da rede de Elman e TDNN após retirada de períodos de inatividade	63

LISTA DE SIGLAS E ABREVIATURAS

ARIMA	– <i>Autoregressive Integrated Moving Average</i> – Autorregressivo Integrado de Média Móvel
FAC	– <i>Funcion Autocorrelation</i>
FACP	– <i>Function Autocorrelation Part</i>
IA	– Inteligência Artificial
MAPE	– <i>Mean Absolute Percentual Error</i> – Erro Percentual Absoluto Médio
MATLAB®	– marca registrada da empresa <i>The Mathworks, Inc.</i>
MLP	– <i>Multi Layer Perceptron</i>
MSE	– <i>Mean Square Error</i> – Erro Quadrático Médio
PACF	– <i>Partial Autocorrelation Function</i>
PDP	– <i>Parallel Distributed Processing</i>
RNA	– Rede Neural Artificial
SARIMA	– <i>Seasonal Autoregressive Integrated Moving Average</i> – ARIMA Sazonal
TDNN	– <i>Time Delay Neural Network</i>

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Justificativa.....	12
1.2	Objetivo.....	14
1.3	Estrutura da monografia.....	14
2	REVISÃO DA LITERATURA	15
2.1	Determinação da demanda.....	15
2.2	Modelo de previsão.....	18
2.3	Redes neurais artificiais.....	23
2.4	Redes de Elman.....	34
2.5	Redes <i>Time Delay Neural Network</i> (TDNN).....	36
2.6	Trabalhos Correlatos.....	37
3	MATERIAL E MÉTODOS	42
4	RESULTADOS E DISCUSSÕES	46
4.1	Ambiente de estudo.....	46
4.1.1	A empresa.....	46
4.1.2	Caracterização dos dados.....	46
4.2	Aplicação das Redes Neurais Artificiais.....	51
4.3	Rede de Elman.....	53
4.4	Rede <i>Time Delay Neural Network</i> - TDNN.....	57
4.5	Gráfico comparativo das redes.....	61
4.6	Reavaliação dos períodos de inatividade.....	63
5	CONCLUSÕES	66
6	REFERÊNCIAS BIBLIOGRÁFICAS	68
	APÊNDICE A – CÓDIGO MATLAB DA REDE DE ELMAN.....	77
	APÊNDICE B – CÓDIGO MATLAB DA REDE TDNN.....	82

1 INTRODUÇÃO

O mercado de automóveis no Brasil tem sofrido grandes mudanças nos últimos anos, com períodos de grandes crescimentos, ajudas governamentais com renúncias fiscais ou diminuição de impostos (UOL, 2014). Porém, o ano de 2015 mostrou-se desafiador para o segmento automobilístico.

Num ambiente extremamente competitivo e instável, os riscos dos negócios são cada vez maiores para todos os tipos de empresas. Neste sentido, o processo de previsão de demanda se torna um dos pontos mais importantes para redução destes riscos e tomada de decisões, cada vez mais integrado a todo processo logístico de uma empresa (MARTINS e CAMPOS, 2006).

Os planejamentos de curto, médio e longo prazos são de difícil elaboração, devido às incertezas nos setores econômicos, sócio político e tecnológico. Por exemplo, as flutuações nos mercados de capital, suprimentos, mão de obra e vendas ajudam na concepção de um ambiente instável e competitivo. Neste ambiente dinâmico, a grande preocupação das empresas é com o que pode acontecer e como atuar sobre estes eventos previamente, ou como adaptar suas estratégias às mudanças previstas (KOTLER, 2000; MOON *et al.*, 1998).

Para concessionárias de veículos automotivos, a previsão de demanda de peças de reposição é um importante componente por trabalharem com itens de alta rotatividade com grande propensão a obsolescência, dada pela constante mudança de modelos ocorridos em períodos de tempos cada vez menores. Neste sentido, deve-se dar especial atenção a esse processo para as peças de reposição não se tornarem fonte de perda de investimento.

Silva (2003) relata que existem vários métodos de se efetuar previsões, alguns mais intuitivos e de natureza prática, conhecidos como qualitativos, e outros mais objetivos com base matemática e estatística, conhecidos como quantitativos. O fato de não haver um método único e ideal para previsão, aplicável a todas as situações, deixa em aberto um amplo espaço para a pesquisa técnico-científica da aplicabilidade e eficiência de cada técnica.

Em ambos os casos, qualitativos ou quantitativos, a partir dos dados históricos, é possível extrair informações que permitem elaborar a modelagem do comportamento de um determinado fenômeno com o intuito de prever seu comportamento no futuro, de tal forma que supondo a continuidade desse comportamento, assegura-se a realização de

previsões com um erro menor do que se pode admitir. Segundo Araújo e Gomes (2005), os dois principais grupos de modelos para previsão de séries temporais baseiam-se em métodos estatísticos e em Redes Neurais Artificiais (RNA's).

Para Pasquoto (2010), os métodos quantitativos mais utilizados são paramétricos: assumem uma ou mais hipóteses que condicionam a aplicação do método. Por exemplo, para estimar os parâmetros de um modelo ARIMA, assume-se haver uma relação entre os valores da série que pode ser explicada em uma equação predefinida como linear.

Há, no entanto, um método quantitativo não paramétrico que por meio de funções não-lineares, aproxima as equações ideais sem reduzi-las explicitamente. O termo não paramétrico não significa que não são feitas suposições prévias sobre o modelo estatístico dos dados de entrada. Esta é a abordagem de Redes Neurais Artificiais (OLIVEIRA, 2003; HAYKIN, 2009)

As Redes Neurais Artificiais (RNA's) representam uma tecnologia que tem raízes em muitas disciplinas: matemática, física, química, ciência da computação além da engenharia. As redes neurais encontram aplicações em campos diversos, tais como modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle em virtude da habilidade de aprender a partir de dados de entrada com ou sem supervisão.

Com o intuito de verificar a aplicabilidade das redes neurais artificiais na previsão de demanda de peças de reposição, buscou-se neste trabalho exemplificar os resultados obtidos a partir do treinamento, validação e previsão utilizando as redes de Elman e da rede *Time-Delay Neural Network* (TDNN), comparando os resultados entre elas e analisando qual resultou no menor erro de previsão com base no *Mean Squared Error* (MSE) e no *Mean Absolute Percentual Error* (MAPE).

1.1 Justificativa

Face ao mundo em constante evolução, em que é necessário encontrar melhores alternativas para administrar as mais diversas situações, a tomada de decisão precisa ser planejada. Para um planejamento efetivo, é importante avaliar quais eventos irão ocorrer e quando. Como a previsão de demanda é um destes eventos, é fundamental, para tomar as decisões adequadas, conhecer e utilizar metodologias que auxiliem o processo de previsão.

Whight e Upadhyaya (1996) relatam que entre os pesquisadores que estudam o processo de previsão de demanda há um crescente interesse pela interação de modelos

estatísticos que sejam mais eficazes. O principal motivo é o fato de serem menos propensos ao viés e poderem extrair muitas informações dos dados coletados no passado, porém se limitam a essas informações.

Lindberg e Zackrisson (1991) afirmam que um dos maiores problemas associados ao uso de previsões no apoio à tomada de decisões é a escolha do método aplicado para gerar a previsão e, segundo Armstrong (2001), pesquisas que contribuem para o desenvolvimento e refinamento de guias para seleção de métodos de previsão são sempre úteis.

De acordo com diversas estruturas neurais e algoritmos de aprendizagem propostos por vários pesquisadores (ZOUCCAS 2009; HAYKIN, 2009; PASQUOTO, 2010; MINE, 2010), as redes neurais possuem certas características exclusivas de sistemas biológicos que entram em conflito com os tradicionais métodos computacionais. Sistemas de computação baseados em redes neurais têm a capacidade de receber, ao mesmo tempo, várias entradas e distribuí-las de maneira organizada de tal forma que as informações armazenadas são compartilhadas por todas as suas unidades de processamento. Esta característica contrasta com os atuais esquemas de memória, em que a informação fica confinada em um determinado endereço.

Esses fatores que distinguem as redes neurais dos demais sistemas e modelos de previsão de demandas são propulsores para o desenvolvimento de pesquisas voltadas para essa matéria. Nas mais diversas áreas do conhecimento, como engenharia, administração financeira, medicina, matemática e outras, as redes neurais têm sido utilizadas com sucesso (PASQUOTO, 2010; MINE, 2010).

Este estudo está focado no processo de geração de previsão de demandas com a utilização de redes neurais para tomada de decisão no varejo de peças de reposição para veículos automovidos. A preocupação central da pesquisa é na exploração de técnicas que auxiliem uma melhor acurácia nas previsões de longo prazo o que possibilita a identificação de obsolescência. Tal processo possibilita ao gestor a correta tomada de decisão quanto ao gerenciamento de compras e vendas, bem como o gerenciamento adequado dos fluxos de estoque e caixa.

Atualmente, a empresa analisada a qual o método proposto é aplicado trabalha com a média móvel aritmética de 12 meses, o que gera certas inconsistências nas previsões, principalmente quando se trabalha com itens cujo gráfico de evolução de consumo seja de tendência com crescimento ou declínio, pois a influência dos meses mais antigos atrapalha de forma significativa na elaboração das previsões futuras.

1.2 Objetivo

O objetivo da dissertação é avaliar o desempenho de Redes Neurais Artificiais de Elman e TDNN na predição de demanda de peças de reposição de veículos automotores identificando quais se adaptam melhor a cada modelo de consumo estudado e como se aplica em cada caso, conseguindo prever com uma antecedência de 12 meses as quantidades demandas, e como consequência possibilitar o planejamento de compra e venda evitando assim que os itens obsoletos permaneçam no estoque.

1.3 Estrutura da monografia

A dissertação está dividida em capítulos, de forma que no capítulo 1 é apresentada a introdução, justificativa e os objetivos do trabalho. Nesse primeiro capítulo, a intenção é permitir um contato inicial do leitor com todo o estudo que será apresentado no decorrer do texto.

No capítulo 2 é feita uma revisão bibliográfica sobre assuntos relacionados com previsão de demanda e rede neural, apresentando as características das duas redes pesquisadas, com suas diferenças, aplicações e principalmente as formas de tratamento, finalizando com alguns exemplos de pesquisas com redes neurais nas mais diversas áreas.

O capítulo 3 apresenta as bases de dados utilizadas, os algoritmos das redes neurais e seus comportamentos na previsão de demanda dos testes realizados.

No capítulo 4 são analisados os resultados obtidos com os testes e algumas discussões são apresentadas.

No capítulo 5 tem-se as conclusões do trabalho e apresentação de proposta para trabalhos futuros.

2 REVISÃO DA LITERATURA

Neste capítulo é apresentada uma revisão bibliográfica, com breves comentários de trabalhos desenvolvidos com a utilização das técnicas de Redes Neurais Artificiais na previsão de demandas e em outras áreas demonstrando o potencial de utilização das redes selecionadas e embasando com conhecimento teórico os resultados verificados.

2.1 Determinação da demanda

Demanda é a quantidade de determinado produto ou serviço que uma coletividade está necessitando e procurando, ou que, por previsões, se avalia que ela necessitará e procurará em determinado momento. Esse conceito apresentado por Dias (2005) ainda esclarece que toda gestão de estoque está pautada na previsão do consumo do material, o qual estabelece estimativas futuras dos produtos acabados comercializados e vendidos.

Martins e Laugeni (2006) relatam que o sinal da demanda é a forma sob a qual a informação chega à área de compras para desencadear o processo de aquisição de bem material ou patrimonial. No caso dos bens materiais, as formas mais comuns são solicitação de compras, reposição periódica, ponto de pedido, caixeiro viajante e contratos com fornecedores.

Kotler (2000) descreve que a demanda de mercado não é um número fixo, mas uma função das condições determinadas. Por esse motivo, pode ser chamada de função de demanda de mercado, a qual não retrata fielmente a demanda de mercado ao longo do tempo. Em vez disso, a curva mostra previsões alternativas atuais da demanda de mercado associadas a possíveis níveis alternativos de esforços de todos os departamentos envolvidos, ou seja, *marketing*, produção, vendas e outros.

Para o mercado automotivo, e no sentido de demonstrar a importância das especificidades de cada mercado, Kotler (2000) ressalta que o potencial de mercado para automóveis em um período de recessão e em um período de prosperidade são bem diferentes, assim como a participação da empresa na demanda em níveis alternativos de esforço de vendas e o quanto ela consegue absorver desse mercado, pois nenhuma empresa consegue absorver 100% do mercado.

Rolim (2001) defende que o maior mercado de peças de reposição é o de automóveis. É a maior frota e onde a concorrência é mais diversificada. Também é nesse segmento onde está a maior quantidade de distribuidores, lojas de peças e centros de serviços, autorizados ou não autorizados, o que acirra a concorrência dificultando o provisionamento correto e apurado das demandas necessárias a determinado período.

A razão que dispara a cadeia de consumo das peças de reposição sempre será a necessidade de uma manutenção preventiva ou corretiva de um veículo ou equipamento automotor. Por esta razão, também será quase desprezível o efeito do posicionamento de preço sobre a elasticidade da demanda de uma peça. No máximo, as estratégias de preço conseguirão deslocar temporariamente o consumo de uma para esta ou aquela marca (ROLIM, 2001).

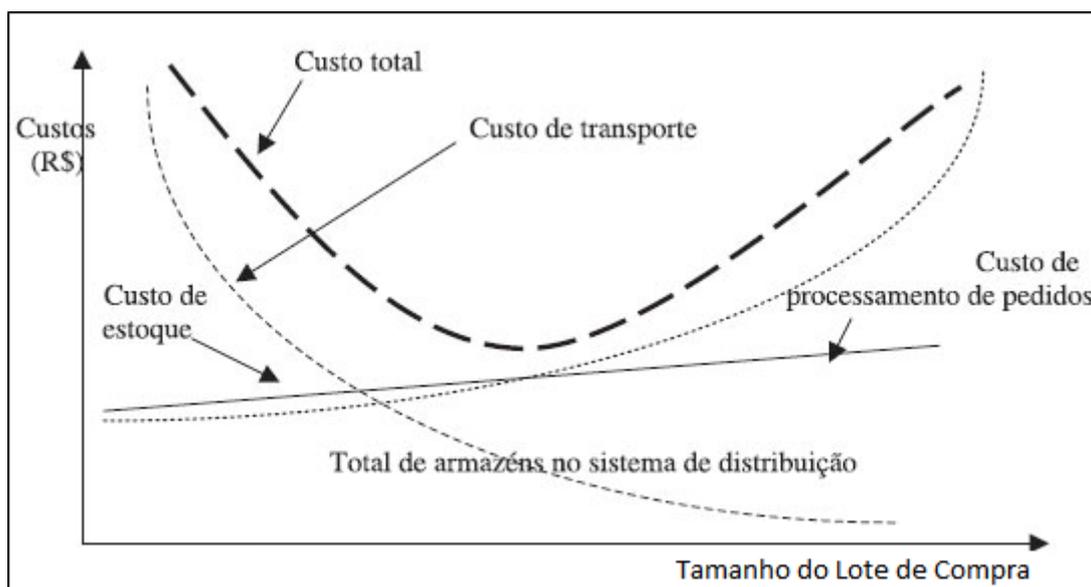
Não há dados divulgados que apontem a taxa de consumo de peças por veículo ao longo dos anos da sua vida útil, até porque cada segmento tem suas peculiaridades. O índice de retenção do veículo na rede assistencial diminui consideravelmente com o seu envelhecimento. Isso determina, inclusive, por quanto tempo o fabricante direcionará esforços produtivos para um modelo em questão. O distribuidor também precisa ter esta visão, para corretamente ponderar quais serão as faixas de produtos e modelos que deverão ser atingidos pela sua estratégia de *marketing* (ROLIM, 2001).

Bukkapatnam *et al.* (2012) apresentam em estudos desenvolvidos na General Motors na China que a previsão de vendas, não só para veículos automotores mas também para as peças de reposição, deve considerar um universo que compreende de 6 a 24 meses de histórico de vendas para o processo de planejamento de demandas de bens relacionados a automóveis, pois os tempos típicos de ciclo de vida de produto têm de 12 a 60 meses de duração. Relatam ainda que a evolução e as dependências com diversas variáveis macroeconômicas não-lineares e não-estacionárias dificultam a previsão precisa de longo prazo, ou seja, acima de 6 meses.

Para Mine (2010), o processo de previsão da demanda representa um passo fundamental para o planejamento empresarial, permitindo dimensionar adequadamente os recursos necessários à empresa e, por isso, é vista como a base do processo de planejamento e constitui-se em uma das atividades mais importantes de um sistema de produção acarretando custos quando do excesso ou escassez do produto demandado.

Martins e Laugeni (2006) colaboram com Mine (2010) ao afirmar que estoque custa dinheiro, pois a necessidade de manter estoques acarreta uma série de custos às empresas, sendo eles diretamente proporcionais à quantidade estocada, inversamente proporcionais à quantidade estocada e independentes da quantidade estocada conforme ilustrado na Figura 1.

Figura 1 - Custo Total do Estoque



Fonte: Adaptado de MARTINS e LAUGENI (2006)

Nota-se na Figura 1 que o ponto de custo total mínimo não corresponde à mesma condição para a qual o custo de transporte é mínimo ou que os custos de estoque ou processamento de pedidos são mínimos. Pelo contrário, o ponto de mínimo custo ocorre em um lugar intermediário entre eles. Isso se dá devido aos custos inversamente proporcionais, como custo de transporte, diminuir conforme aumenta a quantidade estocada. Porém, os custos diretamente proporcionais seguem aumentando conforme o estoque aumenta.

Conforme apresentado por Dias (2005), entre os custos de armazenamento a obsolescência pode ser um grande problema na administração de estoques. Obsoleto é aquele item ou serviço que deixa de ser útil devido ao surgimento de um produto que o substitua ou pelo simples fato da falta de procura do mesmo no estabelecimento que o vende.

Dias (2005) ainda argumenta que a análise dos materiais sem giro e obsoletos trará benefícios, desde o aumento de capacidade de armazenagem até o lucro na venda para terceiros. O que precisa ser considerado é que itens obsoletos não devem permanecer em estoque, pois representam capital parado.

Conforme apresentado por Bukkapatnam *et al.* (2012), os ciclos de vida dos automóveis estão se tornando cada vez menores, elevando significativamente a possibilidade de, principalmente os itens de caracterização do veículo, se tornarem obsoletos. Tal situação ocorre no caso de peças de reposição de veículos automotores,

quando um item fica seis meses sem movimentação de venda ou de compra (ROLIM, 2001).

Dias (2005) relata que, para evitar o problema da obsolescência, deve ser implantado um modelo de previsão de demanda que possibilite identificar com o máximo de antecedência possível as quantidades necessárias para determinado período evitando assim o aumento do nível de estoque, o que reduz a possibilidade do item se tornar obsoleto.

Assim sendo, uma previsão de demanda bem apurada auxilia na mensuração correta das quantidades a serem adquiridas em um determinado período minimizando os custos e auxiliando na maximização do lucro que toda empresa almeja.

2.2 Modelo de previsão

O termo “previsão”, assim como “predição”, pode ser definido como “um processo metodológico para a determinação de dados futuros baseado em modelos estatísticos, matemáticos ou econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida” (MORETTIN; TOLOI, 2004).

Taylor (2005) relata que pode ser difícil entender esse conceito, já que o gerenciamento das demandas, que é parte intrínseca da cadeia de suprimentos, é um assunto técnico e profundo. O mesmo autor ainda descreve que a maioria dos livros oferece fórmulas simplistas para o sucesso, em que uma única solução se adapta a qualquer problema, ou então análises detalhadas indicadas apenas para especialistas.

O processo de previsão de demanda constitui-se em uma das atividades mais importantes de um sistema de produção. Diante dessa perspectiva, o processo é considerado a base do processo de planejamento (SLACK; CHAMBERS; JOHNSTON, 2009).

À luz de Martins e Laugeni (2006, p.226), previsão é definida da seguinte maneira:

Previsão é um processo metodológico para a determinação de dados futuros baseado em modelos estatísticos, matemáticos ou econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida.

Gonçalves (2007) descreve que a utilização de modelos de previsão de demanda é o principal passo operacional na gestão dos estoques. Esses modelos são elaborados a partir de um estudo do histórico de consumo de cada item e da utilização de bases estatísticas que permitam a construção de um modelo matemático que represente o comportamento

do consumo de cada material. Isso resulta em projeções de demanda dentro de níveis adequados que permitam suprir as necessidades com menores estoques e, conseqüentemente, refletirá em uma sensível diminuição dos investimentos em estoque e uma redução dos custos operacionais.

Indiscutivelmente, as previsões fazem parte do planejamento do negócio das empresas onde se faz necessário projetar os cursos de ações futuras com base em estimativas das necessidades de recursos. Estimar a demanda futura de bens e serviços é condição essencial para a elaboração de um plano de trabalho que inclui o dimensionamento das capacidades envolvidas com a definição de equipamentos, recursos financeiros, disponibilidade de mão de obra e da quantidade de materiais necessários à produção.

Gonçalves (2007) ressalta que nenhuma previsão é perfeita. Dessa forma, os valores previstos são fixados dentro de certos limites de tolerância e quanto maior o horizonte de planejamento, mais imprecisas são as estimativas. Assim, prever as necessidades da próxima semana tem maior confiabilidade do que prever a necessidade do próximo ano.

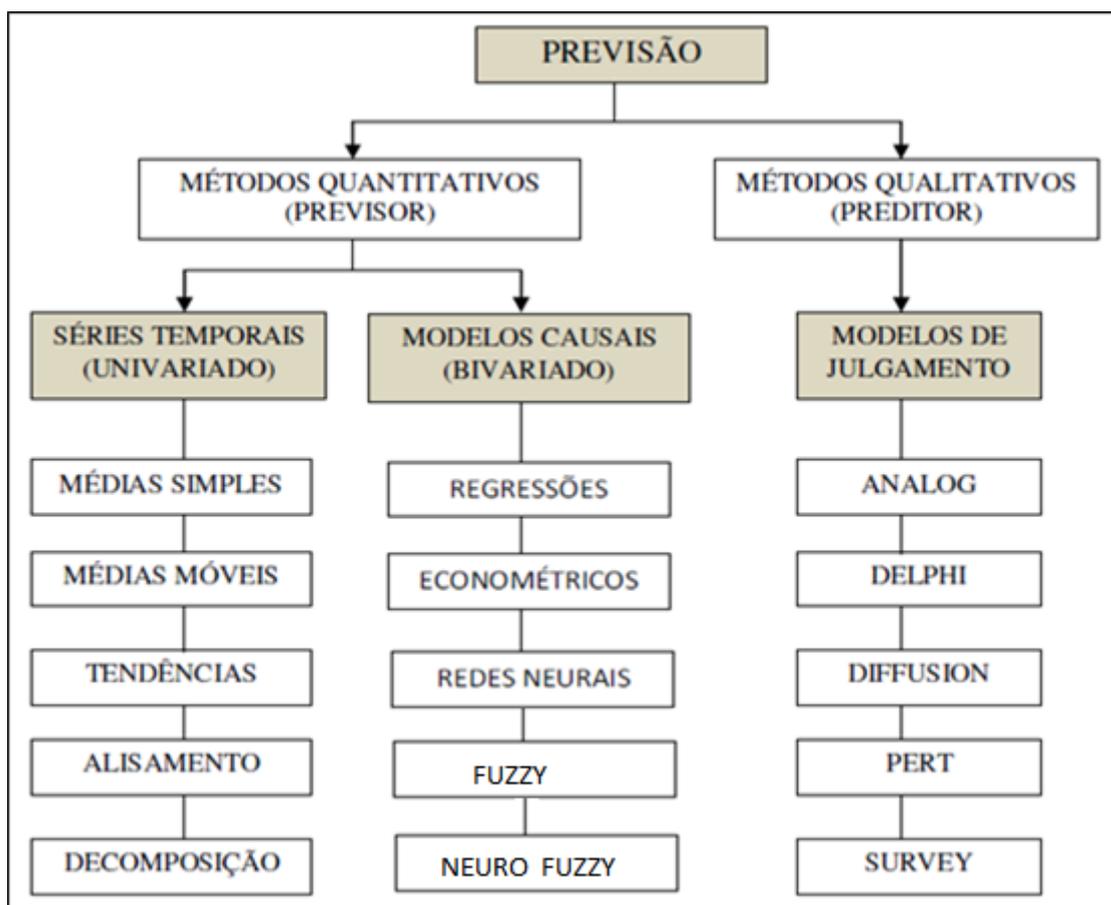
Várias técnicas são utilizadas para fazer as estimativas futuras. Cada uma delas dependerá do grau de sofisticação que se pretende utilizar na modelagem em função do tempo que se dispõe para fazer as previsões e dos custos envolvidos em sua obtenção.

Embora as previsões de demanda possam fornecer informações aos gestores, permitindo que eles sejam eficazes na execução de suas atividades, é importante reconhecer que as previsões não são perfeitas, pois muitos fatores não podem ser previstos e controlados com segurança. Torna-se fundamental uma revisão periódica das previsões e a busca pelo melhor método dentro de um custo razoável, ou seja, a relação custo-benefício entre o gasto com o modelo escolhido e a acurácia dos resultados deve ser avaliada, pois é evidente que, quando os erros de previsão começam a crescer está na hora de alterar o modelo utilizado para fazer as estimativas.

Há diversas formas de classificar os métodos e técnicas de previsão, tais como, por exemplo, técnicas subjetivas e objetivas, além de técnicas não causais e causais (SLACK; CHAMBERS; JOHNSTON, 2009). Os diversos métodos de previsão de demanda podem ser classificados em duas categorias principais: os métodos qualitativos (preditor) e os métodos quantitativos (previsor).

De acordo com um modelo adaptado de Silva (2003), a classificação dos modelos de previsão segue o esquema da Figura 2:

Figura 2 - Métodos de Previsão de Demanda



Fonte: Adaptado de SILVA (2003)

Os métodos qualitativos trabalham com opiniões e sentimentos, sendo subjetivos em sua essência. São métodos que se baseiam no julgamento das pessoas que, de forma direta ou indireta, tenham condições de opinar sobre as vendas futuras, destacando o “consenso de executivos”, baseada em reuniões onde os diretores dos diversos setores da empresa elaboram e argumentam estimativas segundo suas experiências. São úteis quando da ausência de dados ou no lançamento de novos produtos. As pessoas com conhecimento e experiência no assunto tratado emitem opiniões e julgamentos sobre eventos futuros de interesse da empresa que afetam a previsão de vendas. Os métodos qualitativos são normalmente utilizados quando os dados históricos são escassos ou inexistentes e o horizonte de previsão é de médio a longo prazo (GONÇALVES, 2007).

Os métodos quantitativos são aqueles que utilizam modelos matemáticos, com base na estatística, para análise dos dados, como forma de realizar a previsão, permitindo que diferentes especialistas obtenham previsões idênticas (MARTINS e LAUGENI, 2006). Esses métodos são objetivos e fundamentados, podendo trabalhar com grande volume de dados, mas possuem a desvantagem de não prever mudanças estruturais e dinâmicas dos

dados históricos que compõem as séries temporais, o que dificulta suas aplicações.

Para Pozzo (2004) tanto os métodos quantitativos, como os qualitativos, por si só não são suficientes e é necessária a utilização em conjunto de modelos matemáticos que podem levar a uma melhor precisão dos dados desejados, em busca de minimizar os custos envolvidos e otimizar os resultados pretendidos. Os métodos quantitativos podem ser divididos em dois grandes grupos: métodos causais e séries temporais.

Os métodos causais, também chamados de explanatórios, conforme apresentado por Viglioni (2007), realizam o cálculo da previsão da demanda através da elaboração de modelos econométricos. Esses métodos consideram uma relação entre as variáveis estudadas por meio de causalidades, previstas em geral pela teoria econômica. Pode-se citar, por exemplo, o relacionamento da demanda em função do preço e da renda.

Por outro lado, o modelo de séries temporais examina o padrão do comportamento passado de um fenômeno no tempo e utiliza a análise para prever o comportamento futuro desse fenômeno, ou seja, analisa-se o histórico de vendas de um produto, com o objetivo de prever a demanda futura, partindo do pressuposto de que o padrão de comportamento observado no passado forneça informações adequadas para a previsão de valores futuros da demanda. A expressão série temporal indica apenas uma coleção de valores da demanda, tomados em instantes específicos de tempo, normalmente com igual intervalo (SLACK; CHAMBERS; JOHNSTON, 2009).

Pelo fato das previsões baseadas em séries temporais partirem do princípio de que a demanda futura será uma projeção do passado, um dos objetivos da análise das séries temporais é obter modelos de previsão baseados na avaliação dos dados históricos. Desta forma, a previsão pode não constituir um fim em si, mas apenas um meio de fornecer informações para uma conseqüente tomada de decisão. Com isso, a análise de séries temporais é geralmente utilizada em situações de curto prazo, pois se ocorrerem alterações no ambiente externo, onde as vendas se realizam, elas irão afetar a precisão da previsão (VIGLIONI, 2007).

Dentre as metodologias utilizadas, as que mais se destacam são a Média Móvel Aritmética, Média com Suavização Exponencial, Modelos com Tendências e Sazonalidades, Modelos ARIMA (Box-Jenkins), Regressão Linear, Modelos Econométricos e mais recentemente as Redes Neurais Artificiais. Na Tabela 1 são apresentadas as principais características dos métodos de previsão de demandas quantitativos.

Tabela 1 - Principais Características dos Métodos Quantitativos de Previsão de Demanda

Método de Previsão	Características e Utilização
Média Móvel	<p>Uso se o produto não for relevante DIAS(2005)</p> <p>Demanda apresenta comportamento estável DIAS(2005)</p> <p>Modelo simples (MILESKI JÚNIOR, 2007 e MIDE, 2010)</p> <p>Reduz o impacto da aleatoriedade dos dados (MAKRIDAKIS, 1977)</p>
Suavização Exponencial	<p>Pesos maiores às demandas mais recentes (RITZMAN, 2004)</p> <p>Possui variações para inclusão de padrões de tendência e sazonalidade (RITZMAN, 2004 e MAKRIDAKIS, 1977)</p>
Box-Jenkins	<p>Considera que a série é gerada por processo estocástico e o método busca identificar este gerador (VALE; CARVALHO; MADRUGA, 2009)</p> <p>Considera tendência e sazonalidade (VALE; CARVALHO; MADRUGA, 2009)</p>
Regressão Linear	<p>Identifica o efeito da variável de previsão sobre a demanda do produto em análise DIAS(2005)</p> <p>Usa-se quando os dados históricos são disponíveis e as relações entre o fator a ser previsto e outros fatores são conhecidos (RITZMAN, 2004)</p>
Modelos Econométricos	<p>Melhor representação da realidade, já que captura a complexa inter-relação entre fatores que devem ser conhecidos (MAKRIDAKIS, 1977)</p> <p>Usado para planejamento de longo prazo (MAKRIDAKIS, 1977)</p>
Redes Neurais	<p>Consegue representar modelos não-lineares (RAO, 2002; SILVA, 2003; ZOUCAS, 2009)</p> <p>Aproximador universal de função (HILL <i>et al</i>, 1996)</p> <p>Necessita menor extensão de dados (HILL <i>et al</i>, 1996)</p>

Fonte: Adaptado de Branco e Sampaio (2008)

A Média Móvel Aritmética, conforme apresentado por Dias (2005), é um método em que a previsão para o próximo período é obtida calculando-se a média dos valores de consumo nos n períodos anteriores e a previsão gerada por esse modelo é geralmente

menor que os valores ocorridos se o padrão de consumo for crescente, porém será maior que os valores ocorridos se o padrão de consumo for decrescente. Com isso, ela se torna útil para padrões de consumo constante.

A Média com Suavização Exponencial se apresenta dentro de uma grande classe de métodos quantitativos que buscam traduzir as influências ocorridas nas observações ao longo do tempo através de seu próprio histórico. Assim, se um fator externo resultar em alterações nos valores, então a consequência desta ocorrência já estaria incluída nas observações passadas, que influenciarão respostas futuras. Esse modelo também é chamado de Modelo de Médias Móveis Ponderadas e utiliza-se de uma constante de suavização que, quanto maior o seu valor, mais rápido o modelo reagirá a variações elevadas, já que os pesos atribuídos a períodos mais recentes serão maiores que os atribuídos aos mais antigos (MILESKI JÚNIOR, 2007 e MINE, 2010).

Os modelos de Box-Jenkins são modelos paramétricos, também conhecidos como modelos ARIMA (Auto Regressivos Integrados e de Médias Móveis), configurando uma das abordagens mais utilizadas para representação de séries temporais. Vale *et al.* (2009) apresentam o modelo descrevendo que o mesmo possui grande capacidade de generalização, que se traduz na capacidade de representar tanto séries estacionárias quanto não-estacionárias e incluem ainda elementos sazonais e implementações computacionais já disponíveis no mercado.

A Regressão Linear, tanto a simples como a múltipla, é assim chamada porque se considera que a relação da resposta às variáveis é uma função linear de alguns parâmetros. Dias (2005) a apresenta como sendo um método utilizado para determinar a melhor linha de ajuste que passa mais perto de todos os dados coletados, ou seja, é a linha de melhor ajuste que minimiza diferenças entre a linha reta e cada ponto de consumo levantado.

2.3 Redes neurais artificiais

As pesquisas sobre sistemas inteligentes têm progredido por várias décadas, com origem nas pesquisas sobre Inteligência Artificial (IA), exatamente com o interesse de se entender o cérebro ou de se criar uma máquina que mimetize suas funções (MINE, 2010).

Os primeiros estudos relacionados com o conceito de redes neurais surgiram em 1943, com McCulloch e Walter Pitts que conceberam o primeiro modelo de neurônio artificial que se baseia em uma modelagem matemática do neurônio biológico. Estes estudiosos uniram seus conhecimentos em áreas distintas e publicaram o trabalho “*A Logical Calculus of the Ideas Immament in Nervous Activity*”, o qual teve como foco a

apresentação de um modelo matemático que descrevia o comportamento de neurônios (MCCULLOCH e PITTS, 1943). Anos depois, iniciou-se uma pesquisa relacionada com o aprendizado de redes e o primeiro trabalho publicado foi em 1949 por Donald Hebb que sugeriu em seu livro “*Organization of Behavior*” um modo de proporcionar capacidade de aprendizado às redes neurais devido à variação dos pesos de entrada dos neurônios (FERNANDES, 2003).

A época romântica culminou no famoso encontro do *Darhmouth College* onde, segundo Barreto (2000), foi o primeiro encontro conjunto para estudar a Inteligência Artificial (IA), sendo que os anos que se seguiram a esse encontro foram de muito otimismo para os pesquisadores de IA e estes pensavam que brevemente qualquer problema poderia ser resolvido com inteligência artificial. Esta ideia ganhou ainda mais força com o *Perceptron* de Frank Rosenblatt. O *Perceptron* era uma rede neural de duas camadas de neurônios capaz de aprender de acordo com a lei de Hebb.

Minsky e Papert (1969) em seu livro *Perceptrons* provaram que a rede proposta anteriormente por Rosenblatt não era capaz de distinguir padrões linearmente separáveis como o problema do OU-Exclusivo. Esta observação rapidamente fez as pesquisas em redes neurais artificiais estancarem, pois se gerou uma onda de pessimismo na comunidade acadêmica, fase que ficou conhecida como “Época das Trevas” e durou até 1981 (ROISENBERG, 1998). Todavia, as pesquisas em inteligência artificial continuaram com o intuito de resolver problemas em domínios restritos, sendo um estopim para o desenvolvimento de sistemas especialistas.

A Época do Renascimento (1981-1987) caracterizou-se pelo renascimento da inteligência artificial conexionista, tendo mais a função de preparação para a fase seguinte que seria já a Época Contemporânea, na qual vem acontecendo uma espécie de explosão nas aplicações que utilizam RNA's, que se deve a junção de algumas inovações, tais como o algoritmo de treinamento *Backpropagation*, proposto por Paul Werbos em 1974 (porém somente popularizado em 1986 pelo grupo PDP - "*Parallel Distributed Processing*"). Além da utilização de várias camadas de neurônios, considera-se importante também os estudos de John Hopfield, que salientava as propriedades associativas de uma classe de redes neurais que apresentava fluxo de dados multidirecional e comportamento dinâmico (ROISENBERG, 1998).

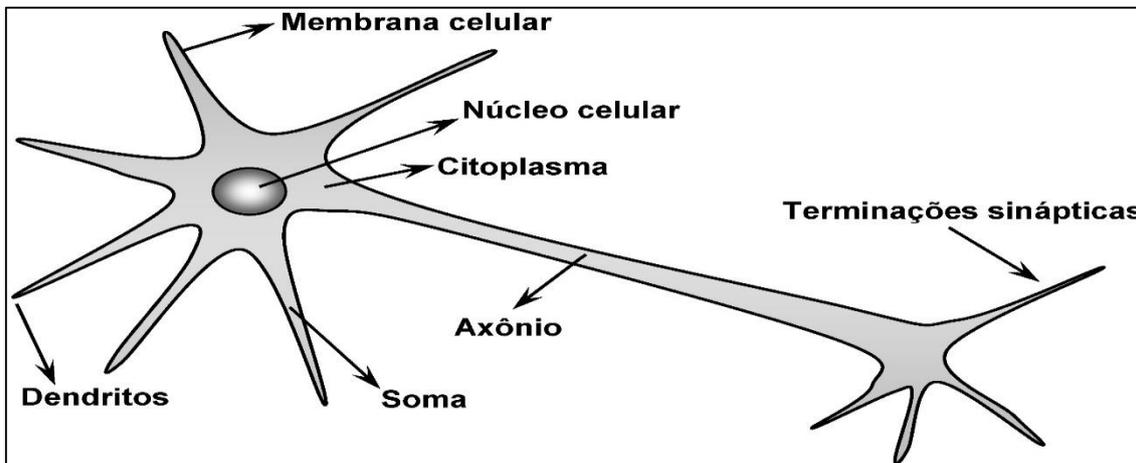
Nos últimos anos, o estudo de modelos de redes neurais artificiais (RNA) tem despertado grande interesse, pois eles são aproximadores da função universal capaz de mapear qualquer função linear ou não-linear e têm sido aplicadas em diversas áreas de

pesquisa, sendo cada vez mais utilizadas para a previsão e classificação, principalmente em áreas onde tradicionalmente se usa modelos estatísticos (ADYA e COLLOPY, 1998; ESTRELLA e MISHKIN, 1998; SWANSON e WHITE, 1997).

Berry e Linoff (1997) afirmam que a modelagem por meio de redes neurais artificiais é uma das técnicas de mineração de dados mais utilizada, sendo largamente empregada em tarefas de classificação e previsão, graças ao desempenho dos computadores que permite, atualmente, que se processem grandes bases de dados.

Pasquoto (2010) descreve as redes neurais como sendo estruturas computacionais que imitam parte do sistema nervoso biológico. A ideia é reproduzir o processamento de informações do cérebro com um modelo artificial de neurônios, que tal como os pares biológicos, se unem funcionalmente através de conexões, formando, assim, as redes neurais. No cérebro humano, o neurônio é a unidade básica, conforme exibido na Figura 3, que recebe os estímulos transmitidos de outros neurônios, sendo o corpo do neurônio, ou soma, responsável por coletar e combinar informações vindas de outros neurônios; e o axônio, que se constitui de uma fibra tubular, responsável por transmitir os estímulos para outras células.

Figura 3 - Estrutura Geral do Neurônio Biológico



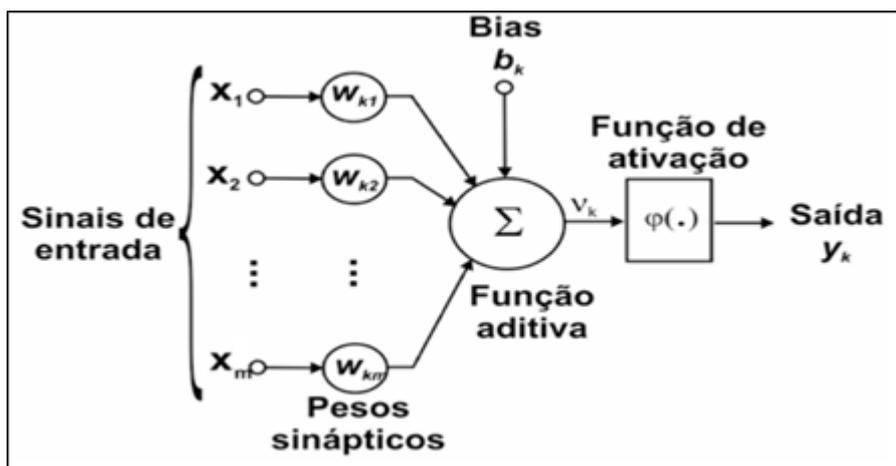
Fonte: Adaptado de HAYKIN (2009).

A comunicação entre os neurônios é realizada através de impulsos. Quando um determinado neurônio recebe impulsos que chegam através de seus dendritos, este os processa e, de acordo com um dado limite de ação, produz uma substância neurotransmissora que flui através do axônio para outros neurônios que, possivelmente, possam estar ligados ao mesmo.

Assim como ocorre no cérebro humano, as RNA's têm no neurônio artificial sua unidade de processamento mais básica. A Figura 4 exibe a estrutura básica do neurônio

apresentado por Haykin (2009). A saída y é dada pela função do somatório das entradas, x_1, x_2, \dots, x_m , ponderadas por seus respectivos pesos, $w_{k1}, w_{k2}, \dots, w_{km}$, de forma a fornecer um modelo matemático do estado de sua sinapse (excitação ou inibição). O peso w_{k1} aplicado à entrada fixa $b_k = 1$ é chamado *bias* e tem a finalidade de controlar o nível da saída v do combinador linear (FREITAS, 2008).

Figura 4 - Neurônio Artificial



Fonte: Adaptado de HAYKIN (2009)

Os símbolos associados à rede são definidos como:

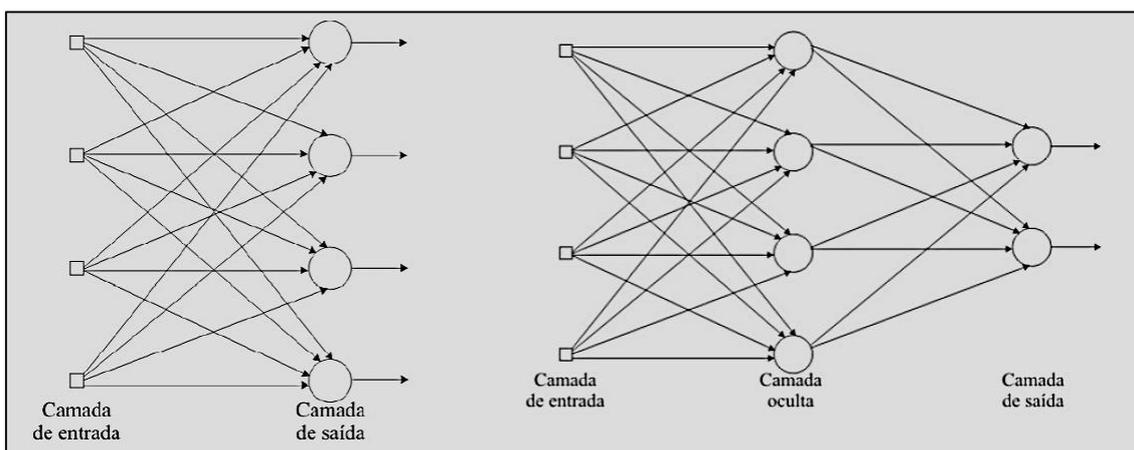
- m é o número de sinais de entrada do neurônio;
- x_m é o m -ésimo sinal de entrada do neurônio;
- w_{km} é o peso associado com o m -ésimo sinal de entrada, no neurônio k ;
- b_k é o limiar do neurônio k , frequentemente chamado de *bias*;
- v_k é uma combinação ponderada dos sinais de entrada e do *bias*, no k -ésimo neurônio;
- y_k é o neurônio de saída
- $\varphi(\cdot)$ é a função de ativação, do k -ésimo neurônio.

Neste modelo, as entradas x_m do neurônio podem ser saídas de outros neurônios, entradas externas, um viés ou qualquer combinação destes elementos. Estas entradas são ponderadas pelos pesos w_{km} que são inspirados na força da conexão sináptica.

Apesar do modelo básico apresentado por Haykin (2009), é relatado que a arquitetura das RNA's variam bastante de acordo com sua finalidade. A maneira como os neurônios estão distribuídos em rede também está muito relacionada com o algoritmo de aprendizagem utilizado. Em geral, a classificação das redes neurais artificiais considera a forma como o processamento flui na rede e o quanto seus neurônios estão dispostos em camadas.

As redes de camada única são as redes com neurônios dispostos em paralelo em uma única camada. Já nas multicamadas há uma ou mais camadas posicionadas entre nós de entrada e a camada que gera as saídas finais da rede. Estas camadas escondidas propagam os sinais até que eles cheguem à saída da rede em um certo momento, conforme exemplificado na Figura 5.

Figura 5 – Exemplo de Arquitetura de Rede (Camada única e Multi Camada)



Fonte: Adaptado de PASQUOTO (2010)

Haykin (2009) e Oliveira (2003) descrevem que as redes podem ainda ser alimentadas à frente (*feedforward*), de tal forma que o processamento se dá sempre em sentido único, da entrada para a saída da rede, ou podem ser recorrentes (*feedback*), de forma que a saída de pelo menos um dos neurônios é reintroduzida em algum ponto anterior da rede configurando recorrência do processamento.

Quanto ao aprendizado, os mesmos autores são unânimes em afirmar que este pode ser supervisionado, sendo a rede treinada tendo como base valores alvo na saída e o erro de saída é usado como parâmetro em um algoritmo iterativo de ajustes de peso, ou não supervisionado, em redes que são caracterizadas pela ausência de indicação de uma saída correta desejada.

As principais características apresentadas pelas RNA's são destacadas por Freitas (2008) e Mileski Júnior (2007), conforme descritas a seguir.

- Capacidade de aprendizagem: o cérebro é capaz de aprender novas tarefas nunca antes executadas. As RNA's se utilizam de exemplos de entradas e saídas, através das quais conseguem, por meio de um algoritmo de treinamento, ajustar sua representação interna de conhecimento e, então, mapear as relações entre as entradas e saídas apresentadas;
- Não-linearidade: podem representar domínios complexos, aproximando

mapeamentos de entrada e saída com não-linearidade virtualmente de qualquer ordem;

- Generalização: são capazes de, diante uma informação incompleta ou parcialmente afetada, completar um raciocínio corretamente. Assim, para entradas desconhecidas, diferentes daquelas apresentadas no conjunto de treinamento, as RNA's são capazes de produzir saídas razoáveis a partir de treinamento adequado;
- Robustez e tolerância a falhas: a eliminação de alguns neurônios não afeta completamente o funcionamento global;
- Paralelismo: como diversos neurônios estão ativos ao mesmo tempo, não existe uma restrição que force o processamento sequencial das instruções;
- Plasticidade: mesmo treinada em um determinado ambiente, a RNA pode ter sua representação do conhecimento adaptada a partir de um treinamento adicional a fim de incorporar mudanças no ambiente;

A capacidade de processamento do neurônio artificial se limita à classificação entre classes linearmente separáveis. Tal limitação é conhecida como problema do “Ou exclusivo” (XOR), que provou que uma função tão simples de se calcular não pode ser resolvida pelo *perceptron*. A solução para o problema era a configuração da rede com a inclusão de uma camada escondida. Porém, o problema não era a arquitetura, mas um algoritmo que fosse capaz de treinar os pesos desta rede multicamadas a fim de se classificar corretamente problemas mais complexos. O surgimento do algoritmo de “retropropagação de erro”, ou *backpropagation*, conseguiu popularizar uma solução para tal problema (MINE, 2010).

A primeira tarefa na elaboração de uma RNA é determinar a quantidade de entradas que serão necessárias para se obter um melhor resultado. Para isso, a utilizar-se-á da análise da autocorrelação parcial ou PACF (em inglês *Partial Autocorrelation Function*) a qual mede a correlação entre observações da série temporal que sejam k períodos afastados, depois de controlar as correlações nas defasagens intermediárias, essas funções são calculadas com o objetivo de verificar se a série é puramente estacionária ou de média móvel, ou uma mescla dos dois tipos (QIAN *et al.* 2015).

Mileski Júnior (2007) ainda descreve que a Autocorrelação parcial mede a relação entre os eventos em diferentes instantes e as suas magnitudes e Mine (2010) utiliza esse parâmetro para definir a quantidade de neurônios na camada de entrada. Porém, a quantidade excessiva de neurônios pode demandar muito tempo de processamento e, por

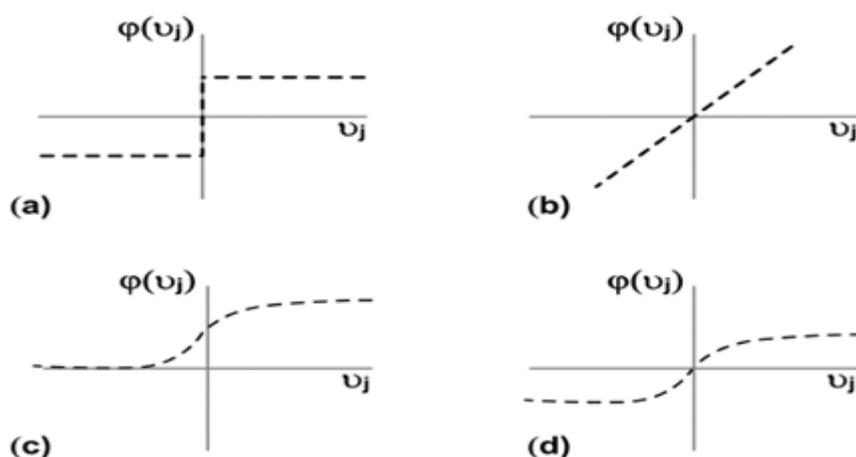
isso, é ideal utilizar a menor quantidade possível de entradas com base na autocorrelação dos valores.

Como observado, a autocorrelação parcial é uma medida de correlação usada para identificar a existência de relacionamento entre valores correntes de uma determinada variável com seus valores anteriores, acumulando os efeitos de todos os intervalos (ou *lags*) em constantes de intervalo (MAKRIDAKIS e WHEELWRIGHT, 1977).

Vaz (2014) relata que a função de transferência ou função de ativação controla a amplitude da saída do neurônio e baseia-se nas reações dos neurônios para os valores de entrada e depende do nível de atividade do neurônio (estado de ativação). Esta premissa se baseia no modelo biológico, onde cada neurônio é, em todos os momentos, pouco ativo. Essencialmente, os neurônios são ativados quando a entrada de rede exceder o gradiente máximo valor da função de ativação, conhecido como limiar atribuído.

Menezes Junior e Barreto (2011) descrevem que, próximo do valor de limiar, a função de ativação tem uma reação bastante sensível. A função de ativação é dependente do estado de ativação anterior do neurônio e da entrada externa e é responsável por gerar a saída de resposta dos neurônios a partir dos valores dos vetores de peso e de entrada. Os tipos mais comuns de função de ativação são a função degrau (a), a função linear (b) e as funções sigmóides (c) logística e (d) tangente hiperbólica, as quais estão representadas na Figura 6, demonstrando o comportamento de seus sinais.

Figura 6 – Representação Gráfica de Diversas Funções de Ativação



Fonte: Adaptado de FIORIN (2011, *et al*)

Para Fiorin (2011, *et al*), as funções de ativação são definidas para uma pequena faixa de valores. A função degrau geralmente trabalha no intervalo compreendido entre -1 e 1, o mesmo intervalo da função tangente hiperbólica, enquanto que a função logística é aplicada no intervalo entre 0 e 1.

Uma característica das funções sigmoidais é a saturação, ou seja, para valores grandes de argumento, a função opera em uma função de saturação e neste caso é importante trabalhar com valores que estejam contidos entre a faixa de -1 e 1 para não atingirem a saturação.

As funções sigmóides são as funções mais empregadas nas camadas internas de uma *Multi Layer Perceptron* (MLP) por serem contínuas, crescentes, diferenciáveis e não lineares. Muitos autores sugerem o emprego da função linear definida na camada de saída da rede de forma que sua saída seja igual ao nível de atividade interna.

Definir o tipo de função a ser utilizado na rede é um fator determinado pela complexidade do problema abordado, uma vez que o peso na rede corresponde basicamente a influência que este tem no sinal de saída. Para pesos positivos é possível se atrelar correspondência com fatores de reforço do sinal de entrada. Quando há pesos negativos, estes simbolizam fatores de inibição.

A correção dos pesos em um ciclo de aprendizado pode ocorrer de duas formas: modo padrão e modo *batch*. No primeiro modo, a correção acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. No modo *batch*, esse ajuste é feito por ciclo e é calculado a partir do erro médio.

Vaz (2014) destaca que um aspecto fundamental na implementação de redes neurais artificiais é o treinamento. Este processo deverá ser concebido de modo que a rede aprenda uma tarefa com sucesso. No entanto, deve-se compreender que uma definição precisa de treinamento é difícil de conseguir, porque não há abordagem direta sobre como fazer isso. Este processo de aprendizagem consiste no ajuste dos pesos sob algumas regras de aprendizagem.

Fiorin *et al.* (2011) esclarecem que na fase de aprendizagem ou treinamento um conjunto de exemplos é apresentado para a rede, que ajusta os seus pesos sinápticos de forma iterativa até que ela extraia as características para representar as informações fornecidas. Posteriormente, estes pesos são fixados e utilizados para gerar soluções para novos valores fornecidos como entrada.

O conhecimento das redes neurais artificiais (RNA) se dá através da ponderação que os pesos da conexão entre os neurônios de diferentes camadas trocam entre si, ou seja, encontrar solução para um determinado problema utilizando RNA seria, a grosso modo, encontrar a melhor topologia de rede, bem como ajustar corretamente os pesos das conexões entre os neurônios.

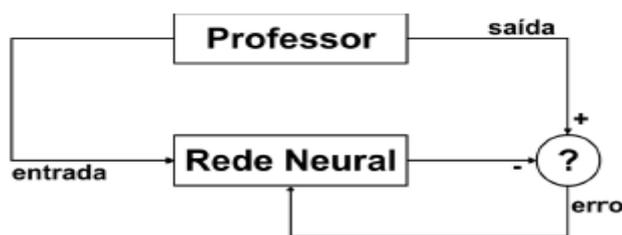
Para o treinamento das RNA's podem ser utilizados diferentes algoritmos de treinamento que diferem basicamente pelo modo como é realizado o ajuste dos pesos, se dividindo em dois paradigmas: aprendizado supervisionado e aprendizado não supervisionado (FREEMAN e SKAPURA, 1992).

O aprendizado supervisionado apresenta em sua estrutura uma espécie de instrutor que confere o quanto a rede está próxima de uma solução aceitável, adaptando na concepção do treinamento os pesos entre os neurônios, de modo a prover uma menor diferença entre a saída desejada e a obtida. Já o aprendizado não-supervisionado não possui conhecimento a priori das saídas da rede, e funciona de modo a distinguir classes de padrões diferentes dos dados apresentados à rede, através de algoritmos de aprendizado baseados geralmente em conceitos de vizinhança e agrupamento (KOHONEN, 1987).

Na aprendizagem não-supervisionada, a rede é ajustada de acordo com regularidades estatísticas dos dados de entrada, de tal forma que ela cria categorias, otimizando em relação aos parâmetros livres da rede uma medida da qualidade que é independente da tarefa a ser executada (KOHONEN, 1987; FREEMAN e SKAPURA, 1992).

Haykin (2009) ainda ressalta que no aprendizado não-supervisionado é fornecido à rede somente valores de entrada que são organizados em diferentes classes de acordo com a semelhança de suas propriedades através do ajuste de seus pesos da rede. No treinamento supervisionado existe um supervisor externo que fornece à rede tanto valores de entrada quanto os valores de saída esperados. O aprendizado supervisionado, ilustrado na Figura 7, é o método mais comum para treinamento das RNA's.

Figura 7 – Mecanismo de aprendizado supervisionado



Fonte: FIORIN *et al.* (2011)

O aprendizado supervisionado pode ser classificado em treinamento dinâmico e treinamento estático. No primeiro ocorrem alterações na estrutura de rede (redução ou aumento no número de camadas, número de nodos em cada camada e número de conexões). Por outro lado, no treinamento estático somente os valores dos pesos sofrem alterações e a tipologia da rede é mantida inalterada.

Em resumo, no treinamento supervisionado estático, a RNA compara o valor de saída calculado com o valor esperado e avalia o erro decorrente das diferenças entre ambos. Assim, com a discrepância conhecida, os pesos sinápticos são modificados de forma a minimizar o erro e encontrar a melhor relação entre as informações de entrada e saída (GUARNIERI, 2006).

Haykin (2009) indica que o algoritmo de treinamento mais utilizado é o *backpropagation*, também conhecido como retropropagação. Este algoritmo utiliza a técnica do gradiente descendente para o ajuste dos pesos sinápticos de tal forma que o erro produzido pela rede atinja um limite pré-estabelecido e o mesmo pode ser utilizado com o aprendizado supervisionado ou com o não-supervisionado.

O algoritmo *backpropagation* foi desenvolvido de maneira independente por vários pesquisadores trabalhando em diferentes áreas aproximadamente na mesma época. Werbos (1974) apresentou o algoritmo enquanto desenvolvia sua tese de doutorado em estatística e o chamou de "Algoritmo de Realimentação Dinâmica". Parker (1982) redescobriu o algoritmo e denominou-o de "Algoritmo de Aprendizado Lógico". Porém, foi o trabalho de Rumelhart, Hinton e Williams (1986) do grupo PDP ("*Parallel Distributed Processing*") do MIT que divulgou e popularizou o uso do *backpropagation* para o aprendizado em redes neurais. Esse algoritmo é a técnica de aprendizado supervisionado mais utilizada para redes neurais unidirecionais multicamadas.

Existem vários métodos para a determinação do momento em que o treinamento de uma rede neural deve ser encerrado. Uma boa determinação destes critérios é fundamental para um bom treinamento e, conseqüentemente, uma boa generalização. Os critérios de parada mais utilizados, conforme apresentado por Prechelt (2012), são o número de ciclos, o erro e a parada antecipada.

O número de ciclos define o número de vezes em que o conjunto de treinamento é apresentado à rede. Um número excessivo de ciclos pode levar a rede à perda do poder de generalização (sobreajuste, do inglês *overfitting*). Por outro lado, com um pequeno número de ciclos a rede pode não chegar ao seu melhor desempenho (falta de ajuste, do inglês *underfitting*).

A parada proveniente do tamanho do erro consiste em encerrar o treinamento após o erro encontrado pela rede e o real ficar abaixo de um valor pré-definido. É importante lembrar que um erro médio muito pequeno não implica necessariamente em uma boa generalização. Neste caso, o *backpropagation* é susceptível a sobreajustar os exemplos de treinamento ao custo da redução da acurácia.

Esse erro pode ser analisado com base no Erro Médio Quadrático (*Mean Squared Error - MSE*), que é constituído pela média dos quadrados dos desvio entre a previsão e a demanda real. Este erro tende a penalizar mais os maiores desvios frente os erros de menor valor. O MSE pode ser definido pela equação 2.1 conforme apresentado por (LOPES, 2002).

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (2.1)$$

Onde:

n é o número de amostras

\hat{Y}_i é a média dos valores de todas as amostras

Y_i é o valor fornecido pelo classificador para a i -ésima amostra

Pode ainda ser aplicado o Erro Percentual Absoluto Médio (*Mean Absolute Percentual Error - MAPE*) que é a média de todos os erros absolutos percentuais (LOPES, 2002). O MAPE fornece uma indicação do tamanho médio do erro através de um percentual do valor observado, independente de ser positivo ou negativo. Tal métrica é definida pela equação 2.2.

$$\text{MAPE} = \sum [(A(t) - F(t)) / A(t)] / N \quad (2.2)$$

Onde:

$A(t)$ = demanda real no período;

$F(t)$ = previsão para o período t ;

N = números de períodos de previsão t .

Na parada antecipada, conhecida em inglês como *early stopping*, o treinamento é interrompido a cada x ciclos e é realizada uma estimação do erro da rede sobre o conjunto de dados de validação. A partir do momento em que o erro medido no conjunto de validação apresentar crescimento, o treinamento é encerrado. O que se deseja com esta técnica é descobrir o momento exato em que a rede começa a perder generalização. Os passos para realizar esta técnica são:

- Dividir os dados em conjuntos de treinamento e de validação;
- Treinar a rede usando só o conjunto de treinamento e avaliar o erro do conjunto de validação a cada k iterações (épocas);
- Interromper o treinamento assim que o erro no conjunto de validação for maior do que era k iterações atrás;
- Utilizar o conjunto de pesos anteriores como o resultado de treinamento.

Quando o treinamento da rede finaliza em função de ter encontrado um mínimo local, mas o erro de treinamento continua alto, isto usualmente significa que as características mais relevantes do problema ainda não foram aprendidas pela rede. Nesse caso, o melhor é alterar os pesos da rede e treiná-la novamente. No entanto, a convergência a um mínimo não global é aceitável no caso em que o erro seja relativamente baixo. Ou seja, não é absolutamente necessário que a rede convirja a um mínimo global para ter um desempenho aceitável (DUDA *et al.*, 2001).

O equilíbrio entre bias (rigidez) e a variância (flexibilidade) da rede é obtido por meio de seu dimensionamento. Quanto maior a sua estrutura, maior o número de parâmetros livres ajustáveis e, conseqüentemente, maior a sua flexibilidade. Porém, quando os dados são apresentados à rede não se tem real conhecimento de sua complexidade, daí a dificuldade do problema de dimensionamento. Redes superdimensionadas podem provocar erros de *overfitting*, e as subdimensionadas podem provocar *underfitting* (ANDRADE, 2011).

O *overfitting* acontece quando a rede memoriza os padrões de treino e perde assim a capacidade de generalizar, deixando de prever corretamente as saídas relativas a pontos que não se encontram no conjunto de treino. O *overfitting* pode ocorrer quando há um número excessivo de neurônios ou camadas para o problema que está sendo abordado. Pode também ocorrer *overfitting* no treinamento, quando a rede neural é treinada com uma quantidade de épocas além do necessário. Já o *underfitting* ocorre quando a rede não é suficientemente treinada para se tornar capaz de produzir resultados satisfatórios, ou seja, quando há um número muito baixo de neurônios ou de camadas para o problema que está sendo abordado. Pode ocorrer também *underfitting* no treinamento, quando a rede neural é treinada com uma quantidade de épocas abaixo do necessário (ANDRADE, 2011).

2.4 Redes de Elman

As redes de Elman (ELMAN, 1991), assim nominadas devido ao seu criador, o professor da Universidade da Califórnia, Jeffrey Elman, são conhecidas como redes recorrentes simples e são um aperfeiçoamento das redes *feedforward* devido à inclusão de realimentação entre as camadas imediata e adjacente. Esta realimentação oferece a rede uma memória de eventos imediatos anteriores, afetando as atualizações dos pesos em cada uma das camadas da rede.

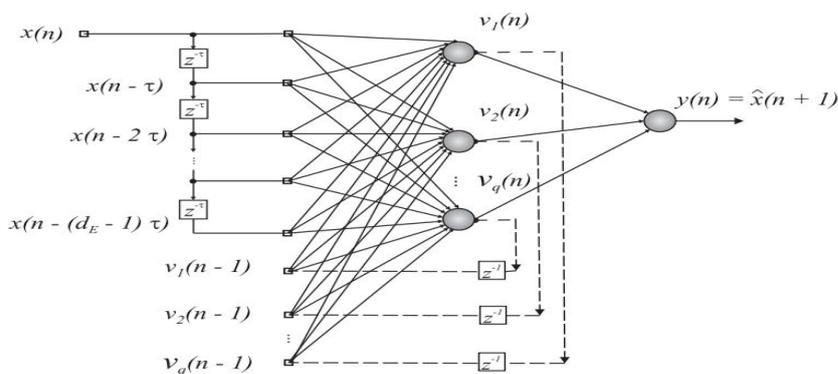
Elman (1991) descreve que nas redes de Elman, além das unidades de entrada,

intermediárias e de saída, há também unidades de contexto, como nas redes parcialmente recorrentes em geral. As unidades de entrada e saída interagem com o ambiente externo, enquanto as unidades intermediárias e de contexto não o fazem. As unidades de entrada são apenas unidades de armazenamento (*buffer*) que passam os sinais sem modificá-los. As unidades de saída são unidades lineares que somam os sinais que recebem. As unidades intermediárias podem ter funções de ativação lineares ou não-lineares, e as unidades de contexto são usadas apenas para memorizar as ativações anteriores das unidades intermediárias e podem ser consideradas como atraso no tempo em um passo.

Ela foi proposta a partir da redefinição das unidades de entrada da rede MLP. Estas unidades, na rede de Elman, passam a ser compostas de duas partes, sendo que a primeira parte corresponde ao vetor de entrada propriamente dito e a segunda parte da entrada da rede de Elman contém as unidades de contexto, cujos valores são obtidos a partir da realimentação das saídas dos neurônios ocultos no instante $n-1$. A realimentação se dá na saída de cada neurônio da camada escondida para todos os neurônios da mesma camada. Uma camada, também escondida, composta de unidades de contexto, simula a memória da rede armazenando os valores das saídas prévias dos neurônios da camada escondida. Os valores das unidades de contexto são a retroalimentação completa para os neurônios da camada escondida e servem como entradas adicionais à rede. Na rede de Elman, os valores da camada de saída não retroalimentam a rede (SCHATZ, 2014).

Na Figura 8 está ilustrada uma rede recorrente de Elman com uma camada oculta. Por simplicidade, esta arquitetura é denotada por Elman ($d_E + q, q, 1$), a fim de destacar as seguintes grandezas: a dimensão do vetor de entrada (d_E , a dimensão do vetor de contexto (q), o número de neurônios ocultos (q) e o número de neurônios de saída (apenas um, neste caso).

Figura 8 - Rede de Elman com uma camada oculta aplicada ao problema de predição de séries temporais.



Fonte: Adaptado de ELMAN (1991)

Schatz (2014) esclarece que a rede Elman funciona da seguinte maneira: no instante t (inicial), o sinal é propagado pela rede e as unidades de contexto, inicializadas com a saída da camada escondida com o valor zero, não influenciarão na saída da rede, ou seja, na primeira iteração a rede se comportará como uma rede *feedforward*. Ainda na primeira iteração, os neurônios escondidos ativarão os neurônios da camada de contexto e esses armazenarão a saída desta iteração que será utilizada no próximo ciclo. O algoritmo *backpropagation* é então aplicado para a correção dos pesos sinápticos, com exceção das sinapses recorrentes que são fixas em 1. No instante $(t + 1)$ o processo é repetido. A diferença é que a partir de agora os neurônios escondidos serão ativados pelas unidades de entrada e pelas unidades de contexto que possuem o valor de saída dos neurônios escondidos no instante (t) .

Para que uma rede Elman tenha mais condições de aprender a resolver um problema, ela requer uma maior quantidade de neurônios na camada escondida. Isto acontece porque o algoritmo da rede de Elman necessita de mais processamento para encontrar os pesos mais adequados para os neurônios da camada de entrada (MOHD, 2004).

Schatz (2014) ainda ressalta que a principal vantagem das redes de Elman é que o número de unidades de contexto não é diretamente determinado pela dimensão de saída, mas sim pelo número de neurônios ocultos. Nas redes de Elman é possível aumentar ou diminuir a complexidade do problema aumentando ou diminuindo a quantidade de neurônios ocultos e assim obter uma maior quantidade de neurônios na camada de contexto.

2.5 Redes *Time Delay Neural Network* (TDNN)

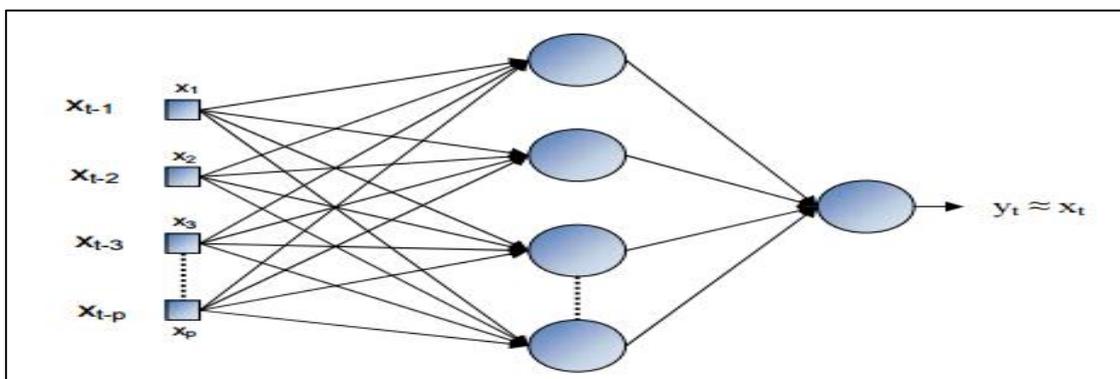
A rede TDNN (em inglês *Time Delay Neural Network*) foi proposta por (WAIBEL, *et al.*, 1989) com a finalidade de resolver o problema de reconhecimento de fonemas isolados utilizando um espectrograma. Em essência, uma TDNN é uma rede neural artificial com arquitetura *feedforward*, onde a resposta da rede no tempo t é baseada nas entradas no tempo $(t-1)$, $(t-2)$, ..., $(t-n)$. Com isso, considera-se um histórico da sequência temporal dos dados.

A TDNN possui uma arquitetura de rede neural artificial cujo objetivo principal é trabalhar com dados sequenciais. Suas unidades reconhecem recursos independentes da mudança de tempo, ou seja, posição de sequência, e geralmente fazem parte de um sistema de reconhecimento de padrão maior (KIM; SHIN, 2007).

As redes TDNN nada mais são do que *Perceptrons* Multicamadas, em que se introduz o aspecto dinâmico e temporal por meio da camada de entrada, ou seja, proporciona-se à rede uma memória de curto prazo (HAYKIN, 2009), aplicando ao vetor de entrada da rede um atraso no tempo. Fica claro então que, para cada valor x_t desejado, a rede treinará com p valores passados, sendo p , portanto, a ordem de predição ou o alcance da memória de curto prazo da rede.

Essas entradas atrasadas no tempo permitem que a rede saiba de parte da história da variável no tempo t , possibilitando a solução de problemas de decisão mais complexos, especialmente aqueles dependentes do tempo (KIM e SHIN, 2007). Esse mecanismo pode ser ilustrado na Figura 9.

Figura 9 – Topologia de Uma Rede TDNN



Fonte: Adaptado de HAYKIN (2009)

O processo de aprendizado de uma rede com entradas atrasadas é semelhante à rede convencional (SILVA *et al.*, 2010). Sendo assim, sua principal diferença está nos conjuntos de dados, onde as amostras são organizadas considerando o atraso entre elas.

2.6 Trabalhos Correlatos

Foram selecionados alguns trabalhos que tratam da previsão de séries temporais mediante redes neurais em diferentes áreas ao longo dos últimos 21 anos com o intuito de exemplificar a evolução da pesquisa nessa área. Em sua maioria, tais pesquisas procuram comparar os resultados obtidos mediante a utilização de métodos estatísticos e aqueles obtidos pela aplicação das redes neurais.

Abelém (1994) investigou a utilização de Redes Neurais Artificiais (RNA) aplicadas a séries temporais financeiras, para fazer previsões do preço do ouro no mercado internacional. Os resultados obtidos pelas RNA's foram comparados com o modelo de Box-Jenkins e, segundo o autor, comprovaram a superioridade das RNA's no

tratamento de dados não-lineares.

Mueller (1996) compara os modelos convencionais de Médias Móveis e Alisamento Exponencial Simples com Redes Neurais na previsão do preço de ações. Justifica a utilização da RNA pela dificuldade dos métodos estatísticos convencionais em tratar observações em ambientes extremamente dinâmicos, próprios do mercado acionário, enquanto que as RNA's, por sua capacidade de generalização são mais capazes para lidar com esse problema. Conclui que os modelos conexionistas (RNA's) geram previsões mais precisas que as dos métodos convencionais aplicados.

Castro (2001) utilizou Redes Neurais RBF combinadas com a técnica de decomposição em componentes principais para a previsão de séries temporais de diferentes áreas: ocorrências de manchas solares, intensidade de um *far-infrared-Laser*, intensidade luminosa da estrela anã-branca, taxa de câmbio do Dólar Americano em relação ao Franco Suíço, número de pacotes externos Ethernet em uma rede local, preço de fechamento diário de ações da Telesp Celular, Eletrobrás, CEMIG e Petrobrás. Concluiu que as RNA's têm capacidade de aprender padrões subjacentes presentes nesses conjuntos de dados, apresentando melhor desempenho que os métodos estatísticos convencionais, sugerindo a utilização de Algoritmos Genéticos para obtenção dos modelos que melhor representem os dados analisados.

Roitman (2001) utilizou os modelos estatísticos, Auto-Regressivos-Integrados-Médias-Móveis (ARIMA(p,d,q)), Alisamento Exponencial (Sazonal e Winters) e de Tendência Linear (com Erros Autoregressivos e Termos Sazonais) e as Redes Neurais do tipo *Perceptron* Multicamadas (MLP), com Atraso no Tempo (TDNN), com Tempo Adaptável Continuamente (CATNN), de Regressão Generalizada (GRNN) e com Função de Base Radial (RBF) para a predição do Índice de Desemprego Aberto-IDA no estado de São Paulo, com a utilização de Algoritmo Genético para a definição das configurações ótimas das RNA's. Concluiu que, de uma forma geral, os métodos estatísticos e de redes neurais são semelhantes em termos de precisão e de tendência, com o modelo estatístico Winters Aditivo e a rede neural de Regressão Generalizada sendo aqueles que melhor se adaptaram aos dados analisados.

Gomes (2005) comparou a utilização de redes neurais recorrentes de Elman e Jordan com modelos padrão tipo ARIMA e ARFIMA, para previsão de séries temporais econômicas, tanto de memória curto prazo quanto de longo, concluindo que as redes neurais são mais vantajosas para a previsão das séries utilizadas nas taxas de inflação dos Estados Unidos e do Reino Unido e de outros países desenvolvidos.

Figueiredo (2008) utilizou a metodologia de Box-Jenkins e a técnica de redes neurais de funções de bases radiais (RBF) sobre dados de vendas de uma linha de produtos de uma empresa da região de Joinville-Santa Catarina, com o objetivo de avaliar as duas técnicas na previsão de valores futuros da demanda desses produtos, para adequar a inicialização da programação de sua produção. Concluiu que tanto os modelos ARIMA de Box-Jenkins como as redes neurais apresentaram bons resultados, com as redes RBF se comportando de forma mais adequada, apresentando o menor RMSE (erro quadrático médio), calculado sobre os valores previstos, para todos os 10 produtos avaliados.

Zoucas (2009) realizou um estudo sobre várias redes neurais, tais como *Perceptron*, Redes Lineares, *Perceptron* Multicamadas, Redes BAM e ART, Rede Probabilística, Hopfield, Kohonen, TDNN, Rede de Elman e Jordan, além dos algoritmos *Backpropagation* e *Levenberg-Marquadt*. Dentre estes escolheu a rede TDNN para a previsão das demandas e o desempenho dos modelos estudados foi analisado pelos índices MSE e MAPE.

Pasquoto (2010) elaborou um comparativo entre a rede neural de Elman e a metodologia de Box-Jenkins para prever a demanda de produtos farmacêuticos, adubos e tráfego aéreo e em todos os casos Box-Jenkins se sobressaiu em relação a RNA, concluindo que não é compensador a utilização de uma metodologia que demanda mais tempo, recursos e conhecimentos para se chegar a um resultado menos satisfatório. O desempenho foi analisado com base nos resultados do MSE.

Mine (2010) aplicou a metodologia de redes neurais artificiais na previsão de demanda de autopeças, traçando um estudo comparativo com um trabalho de referência da literatura, que é baseado em métodos de suavização exponencial e de médias móveis. Ele agrupou os produtos em 10 categorias de acordo com a proximidade espacial, totalizando 72 observações mensais. As previsões geradas foram classificadas qualitativamente seguindo o critério de menor erro percentual absoluto médio (MAPE), e o modelo RNA se mostrou potencialmente superior em 70% das instâncias consideradas, frente aos melhores modelos tratados pelo autor e efetivamente superior em 60% do total.

Lima (2014) testou métodos econométricos e de inteligência artificial para o problema de previsão de séries temporais, em especial regressão linear múltipla e rede neural com regra Delta com o intuito de prever um passo à frente quanto a produção da indústria de transformação do Estado de Goiás. Os erros das estimativas em todos os modelos foram submetidos ao teste de normalidade para validar a adequação do modelo.

Ao final, os modelos foram comparados utilizando MSE, MAPE e desvio padrão para identificar o melhor modelo e método adequado para a predição da produção da indústria de transformação e chegou-se à conclusão de que a rede neural construída apresentou resultados satisfatórios mostrando-se adaptativa, apesar das séries não apresentarem comportamento de série temporal com identificação de padrões, com poucas sazonalidades, mudança de tendência e ausência de característica cíclica.

Song *et al.* (2014), com a utilização da ferramenta SVMlab 1.8 do Matlab® e tendo como parâmetro de validação da rede o MAPE e o MSE, buscaram testar a rede neural para determinar a previsão de demanda de peças portuárias conseguindo diminuir o inventário do estoque devido a uma melhor administração das previsões de demandas resultando em compras mais eficientes.

Tabela 2 - Trabalhos Relacionados - Previsão de Séries Temporais Mediante RNA

AUTOR	MODELOS UTILIZADOS	MELHOR PREVISÃO	SÉRIES UTILIZADAS
Abelém (1994)	RNA (MLP) BOX-JENKINS	RNA	PREÇO DO OURO
Mueller (1996)	RNA (MLP) MÉDIAS MÓVEIS ALISAM. EXPONENCIAL	RNA	PREÇO DE AÇÕES
Castro (2001)	RNA (RBF) ESTATÍSTICOS	RNA	TAXA DE CÂMBIO MANCHAS SOLARES PACOTES ETHERNET PREÇOS DE AÇÕES
Roitman (2001)	RNA (MLP,TDNN,CATNN, GRNN) AUTOREGRESSIVOS ALISAM. EXPONENCIAL	IGUAIS	INDICE DE DESEMPREGO
Gomes (2005)	RNA (ELMAN, JORDAN) ARMA/ARIMA	RNA	TAXAS DE INFLAÇÃO
Figueredo (2008)	RNA (RBF) BOX-JENKINS	RNA	DEMANDA DE PRODUTOS
Zoucas (2009)	RNA(PERCEPTRON) RNA(LINEARES) RNA(BAM) RNA(ART) RNA(HOPFIELD) RNA(KOHONEN) RNA(TDNN)	TDNN	PREVISÃO DE SÉRIES TEMPORAIS DE SEGMENTOS INDUSTRIAIS

	RNA(ELMAN) RNA(JORDAN)		
Pasquoto (2010)	RNA (ELMAN) BOX-JENKINS ARIMA SARIMA	BOX E JENKING	SÉRIES TEMPORAIS DE PRODUTOS FARMACEUTICOS ADUBOS E TRÁFEGO AÉREO
Mine (2010)	MÉDIAS MÓVEIS, SUAVIZAÇÃO EXPONENCIAL, HOLT-WINTERS, PEGELS, ARIMA (BOX- JENKINS), RNA	RNA	PREVISÃO DE DEMANDA DE SÉRIES TEMPORAIS DE AUTOPEÇAS
Lima (2014)	REGRESSÃO LINEAR MÚLTIPLA, REGRESSÃO <i>STEPWISE</i> , RNA – REGRA DE DELTA	RNA	PREVISÃO DE SÉRIES TEMPORAIS NA INDUSTRIA DE TRANSFORMAÇÃO NO ESTADO DE GOIÁS
Song <i>et al.</i> (2014)	RNA	RNA	PREVISÃO DE PEÇAS DE REPOSIÇÃO PORTUÁRIA

Fonte: Elaborado pelo autor (2016)

Em praticamente todos os trabalhos listados na Tabela 2 em que se utilizam redes neurais, concluiu-se que as RNA's apresentam melhores resultados quando comparados com os métodos estatísticos/econômicos.

3 MATERIAL E MÉTODOS

Este capítulo aborda a metodologia a ser utilizada para realização deste trabalho. Segundo Gil (1995), o objetivo fundamental de uma pesquisa é descobrir respostas para problemas mediante o emprego de procedimentos científicos.

Lakatos e Marconi (1996) sustentam que toda pesquisa científica tem como característica comum o emprego de métodos científicos. O método de pesquisa ou metodologia compreende o conjunto das atividades sistemáticas e racionais que, com maior segurança, possibilitam o alcance do objetivo, trocando o caminho a ser seguido, detectando erros e auxiliando nas decisões do investigador.

Dentre os métodos de pesquisa, o estudo de caso vem sendo considerado um dos mais poderosos métodos de pesquisa na gestão de operações, particularmente no desenvolvimento de novas teorias. Yin (2001) define o estudo de caso como uma investigação empírica que investiga um fenômeno contemporâneo dentro de seu contexto da vida real, especialmente quando os limites entre o fenômeno e o contexto não estão claramente definidos.

Yin (2001) ainda esclarece que há, predominantemente, três tipos de estudo de caso, dependendo dos objetivos para o qual ele é usado: exploratório, explanatório e descritivo. O exploratório é uma espécie de estudo piloto que pode ser feito para testar as perguntas norteadoras do projeto, hipóteses, e principalmente os instrumentos e procedimentos. O qual tem por objetivo mostrar ao leitor uma realidade desconhecida sem procurar estabelecer relações de causa e efeito, mas apenas mostrar a realidade como ela é, embora os resultados possam ser usados posteriormente para a formulação de hipóteses de causa e efeito.

Segundo Voss, Tsikriktsis e Frohlich (2002), o estudo de caso é usado para testar as hipóteses e para o desenvolvimento de teorias. Na maioria das pesquisas com estudos de caso existem algumas hipóteses iniciais que podem ser diretamente testadas usando-se os dados do caso. Entretanto, em outros estudos de caso o foco pode ser também o desenvolvimento de teorias e o desenvolvimento ou ajuste de novas hipóteses a partir dos dados coletados.

Este estudo, por testar a hipótese de que as redes neurais artificiais conseguem identificar o padrão de demanda das peças de reposição de veículo automotores, se caracteriza como estudo de caso exploratório ao buscar o desenvolvimento de teorias

aplicadas a uma série piloto investigando um fenômeno da vida real.

Para implementação, execução e testes das redes neurais, foi escolhido o *software Matlab® R2014b*, desenvolvido por MathWorks Inc. (1984-2014). Este *software* possui as vantagens de ser amplamente utilizado pela comunidade científica, facilitando sua aceitação além de possibilitar a criação visual de redes neurais através de uma interface gráfica que possui arranjos e redes desde as mais simples até redes mais complexas e, além disto, tais redes podem ser desenvolvidas através de *toolbox* específicos ou linhas de comando o que oferece uma gama de opções maiores. O desenvolvimento deste trabalho de pesquisa foi desenvolvido em quatro etapas:

A primeira etapa: Revisão bibliográfica sobre os métodos de previsão de demandas.

Dentre os vários métodos de previsão, escolheu-se trabalhar com as Redes Neurais Artificiais devido a vários trabalhos, artigos, dissertações e teses demonstrarem sua capacidade adaptativa a vários tipos de problemas, lineares ou não-lineares, auxiliando de forma ativa na solução do problema, conforme apresentado na seção 2.7.

A segunda etapa: Coleta e escolha dos dados.

Nesta etapa foram coletados os dados referente às vendas de todas as peças de reposição de veículos automotores de uma concessionária de Goiânia no período de março de 2008 a fevereiro de 2015.

A escolha dos itens a serem trabalhados se deu mediante sua representatividade quanto à importância, relevância, tipo de consumo existente e aplicabilidade nos modelos comercializados. Tais itens conseguem representar o consumo de diversas famílias o que possibilitou a observação do comportamento das RNA's nos diversos tipos de demandas existentes tais como consumo de tendência crescente ou decrescente, sazonal ou constante. Além dos modelos apresentados, devido à diminuição do ciclo de vida dos automóveis, para alguns itens não existem movimentações em todos os 84 meses analisados, o que possibilitou acompanhar o comportamento da rede frente a tais características.

A terceira etapa: Tratamento dos Dados.

Vergara (2006) afirma que o tratamento de dados refere-se àquela seção na qual se explica para o leitor como se pretende tratar os dados, justificando por que tal tratamento é adequado aos propósitos desta pesquisa. Assim, os dados analisados neste trabalho

levam em consideração os objetivos pré-definidos. Nessa etapa foi realizada uma análise exploratória dos dados referentes às vendas dos produtos.

Charu e Yu (2001) detalham o tratamento do *outlier*, que em estatística é uma observação que apresenta um grande afastamento da norma para uma variável ou população ou são inconsistentes com elas. Tais observações são também designadas como anormais, contaminantes, estranhas, extremas ou aberrantes. A existência de *outliers* implica, tipicamente, em prejuízos a interpretação dos resultados dos testes estatísticos aplicados às amostras por desviar de outros fatos a ponto de gerar suspeitas de que foi gerado um mecanismo diferente.

Os *outliers* podem afetar o resultado das análises estatísticas. No estudo de Osborne e Overbay (2004) são apontados três problemas ao considerar os *outliers* como aumento da variância do erro associado a menor poder estatístico, a piora na normalidade dos dados e a influência nos estimadores obtidos, como os coeficientes de correlação, médias, desvio padrão, coeficiente de regressão, etc.

Diante disso, é importante que a identificação e a análise dos *outliers* seja realizada assim que possível. Após identificados e analisados, deve-se decidir se os *outliers* serão mantidos ou removidos da pesquisa. Para Hair J. *et al.* (2010), os *outliers* devem ser mantidos, a menos que sejam muito discrepantes e que não sejam elementos representativos da amostra. Se os *outliers* forem representativos, eles devem ser mantidos para assegurar a generalização da amostra. De acordo com Pardoe (2006), a remoção dos *outliers* deve ser justificada, caso afete substancialmente algum dos parâmetros.

Com isso, as vendas consideradas *outliers* foram excluídas das séries temporais para que não influenciassem de forma prejudicial o resultado obtido pela RNA. As vendas esporádicas, oriundas principalmente de vendas no atacado, onde concorrentes, principalmente de outros estados, compram grandes quantidades que muitas vezes a fábrica por uma questão estratégica deixou de fornecer temporariamente.

Além disso, dos registros extraídos do banco de dados da concessionária nem todos devem ser considerados como demanda, uma vez que existem situações em que há necessidade de movimentação no estoque para transferência de itens para o imobilizado da empresa ou para filiais, para manutenção de veículo pertencente à própria frota da empresa ou ainda casos em que promoções e descartes com o intuito de diminuir os níveis de estoques exigem tal emissão de nota fiscal. Além desses fatores, deve-se retirar

também as devoluções aos fornecedores ou remessas para garantia e demonstração de produto.

Outro tratamento a que os dados foram submetidos é a normalização. Silva *et al.* (2010) descreve que a normalização tem por propósito minimizar os problemas oriundos do uso de unidades e dispersões distintas entre as variáveis, as quais podem ser normalizadas segundo a amplitude ou segundo a distribuição. Tal normalização se justifica devido às séries históricas apresentadas serem muito heterogêneas. Assim sendo, os dados de entrada nas redes foram normalizados conforme apresentado na equação 3.1

$$y = \frac{(a_t - \bar{a})}{\sigma_a} \quad (3.1)$$

Onde:

y = valor normalizado

a_t = valor real ou observado

\bar{a} = média amostral

σ_a = desvio padrão da amostra

A quarta etapa: Implementação do método.

Nesta etapa buscou-se os melhores modelos para implementação do método com os respectivos testes que definiu o número de neurônios nas camadas de entrada e camada oculta, bem como as funções de ativação e os algoritmos de treinamento que seriam utilizados nas redes de Elman e TDNN.

Para que essas definições fossem validadas, fez-se 700.000 iterações com as mais diversas variações em cada um dos parâmetros possíveis em cada rede buscando a configuração que tenha melhor adaptação ao modelo de gráfico de evolução de consumo apresentado.

A quinta etapa: Análise dos resultados.

A última etapa discute os resultados obtidos com a aplicação das Redes Neurais Artificiais de Elman e TDNN, fazendo um comparativo entre os resultados obtidos em cada uma. Para se definir a qualidade do resultado utilizou-se como padrão o menor erro médio quadrático (*Mean Squared Error - MSE*) e o maior erro percentual médio absoluto (*Mean Absolute Percent Error - MAPE*).

4 RESULTADOS E DISCUSSÕES

Neste capítulo apresenta-se o ambiente de estudo, as especificidades aplicadas a cada rede e a discussão dos resultados encontrados na aplicação das redes neurais, demonstrando o potencial de cada uma na previsão de demanda de itens de reposição.

4.1 Ambiente de estudo

O ambiente do qual os dados foram extraídos, tratados e aplicadas às técnicas de redes neurais artificiais tem suas particularidades que o diferenciam devido ao segmento, o público-alvo a que atende, além do próprio mercado no qual está inserido.

4.1.1 A empresa

A empresa foco do estudo é uma concessionária de veículos automotores com mais de 20 anos de mercado, situada em Goiânia – Goiás, que atualmente conta com mais de duzentos funcionários distribuídos nas áreas administrativas, venda de veículos novos e seminovos, bem como o departamento de pós-vendas que engloba a parte de peças, oficina mecânica, lanternagem e instalação de acessórios.

Atualmente, o departamento de compras, que é responsável por fazer a previsão das necessidades de peças que serão utilizadas na área de mecânica, lanternagem, pintura e venda no balcão, conta com um *software* que auxilia nessa tarefa, apesar disso, o conhecimento prático do profissional é de suma importância, uma vez que o sistema atual trabalha com a média móvel aritmética com base nos últimos 12 meses e essa técnica tende a diminuir a previsão quando o consumo é crescente e aumentar a previsão quando o consumo é decrescente.

A empresa é revendedora de uma marca que possui apenas cinco modelos compondo o mix de produto da concessionária e cada modelo possui três versões que, visualmente, pouco se diferenciam entre si. Devido a essa particularidade, o estoque de peças conta hoje com 4.325 itens diferentes, que, com um investimento de pouco mais de R\$ 3.000.000,00, tem conseguido atender a necessidade do pós-vendas.

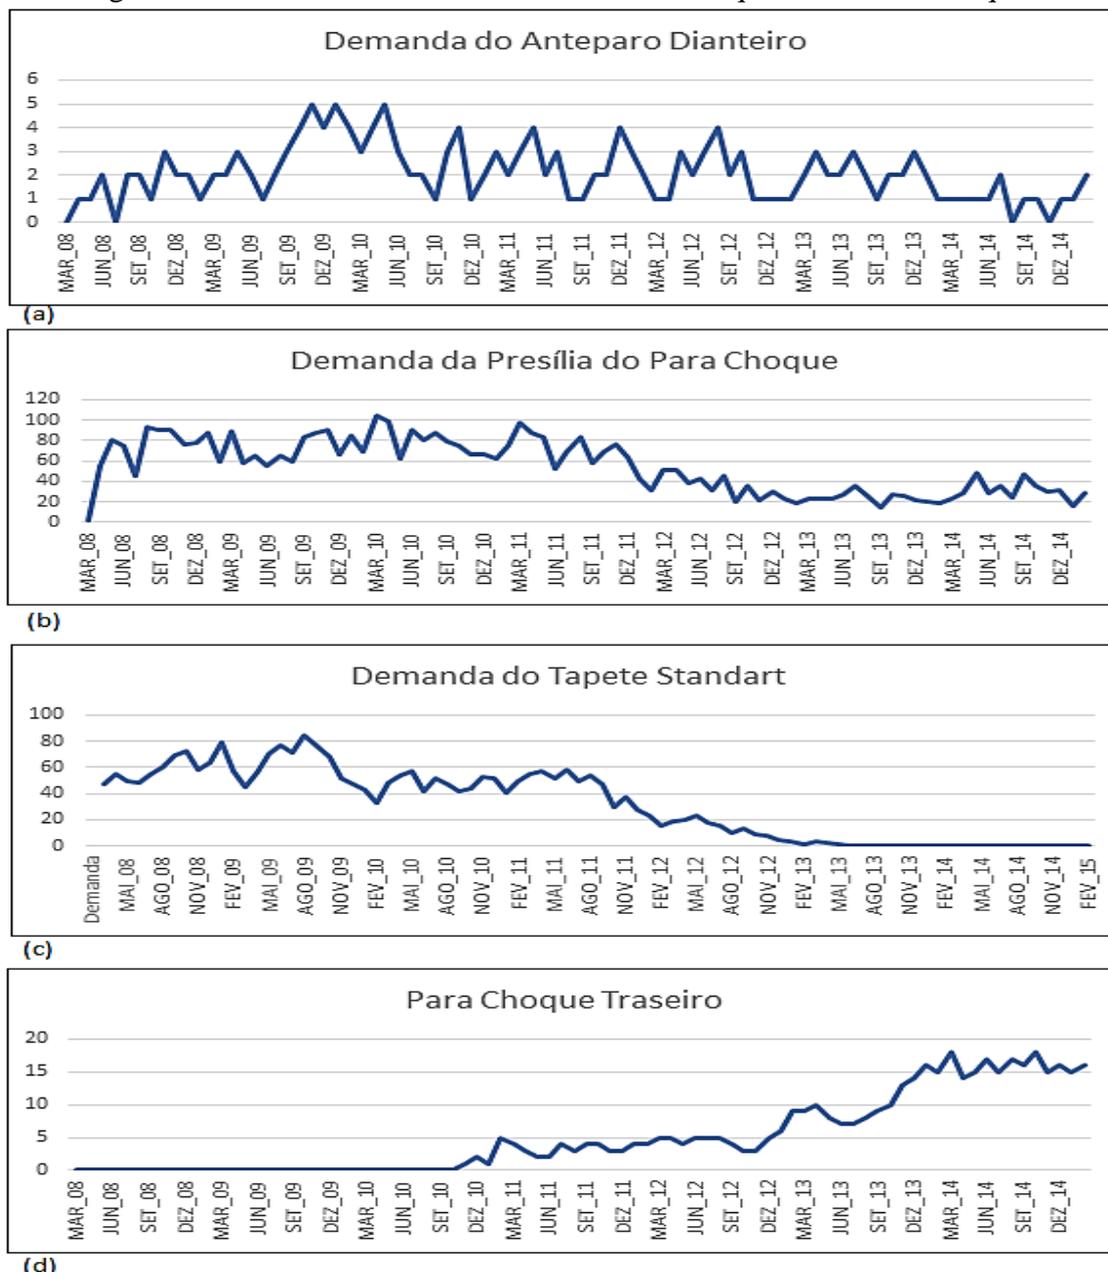
4.1.2 Caracterização dos dados

A série em estudo consta de 84 observações mensais, abrangendo o período de março de 2008 a fevereiro de 2015, referentes ao consumo de peças de reposição para veículos

automotores utilizadas na oficina e funilaria, bem como as vendidas no balcão e no atacado.

Devido ao ciclo de vida de produto ser cada vez menor, ocasionado pela mudança de modelos a cada quatro anos em média, muitos dentre os itens analisados não possuem demandas em todos 84 períodos, enquanto que outros, por serem quase que universais possuem vendas em toda a série analisada conforme apresentado na Figura 10.

Figura 10 – Gráfico com os dados de consumo de quatro itens do estoque.



Fonte: Elaborado pelo autor (2016)

Na Figura 10 pode-se notar a diversidade de variação de demanda existente entre os itens analisados o que dificulta a utilização de uma única forma de prever a demanda, seja

por meio dos métodos qualitativos ou quantitativos tradicionais, seja por meio das redes neurais artificiais.

Outro fator de relevância ao se extrair os dados para a determinação das necessidades demandadas é o conhecimento da base com a qual se trabalha para retirada de movimentações no estoque, pois algumas não são consideradas como vendas e logo não podem ser vistas como demandas. Essas movimentações são oriundas de devoluções a fornecedor, transferências entre filiais, promoções específicas e principalmente os descartes que são feitos para eliminar do estoque os itens que estão com mais de 6 meses sem movimentação e são considerados tecnicamente obsoletos.

Pelo fato das informações serem retiradas de um banco de dados Oracle® já consolidado e em funcionamento por quase 10 anos, houve a necessidade de eliminar os *outliers* para que as movimentações fossem filtradas e consideradas apenas as vendas reais, para se mensurar melhor a verdadeira demanda mensal.

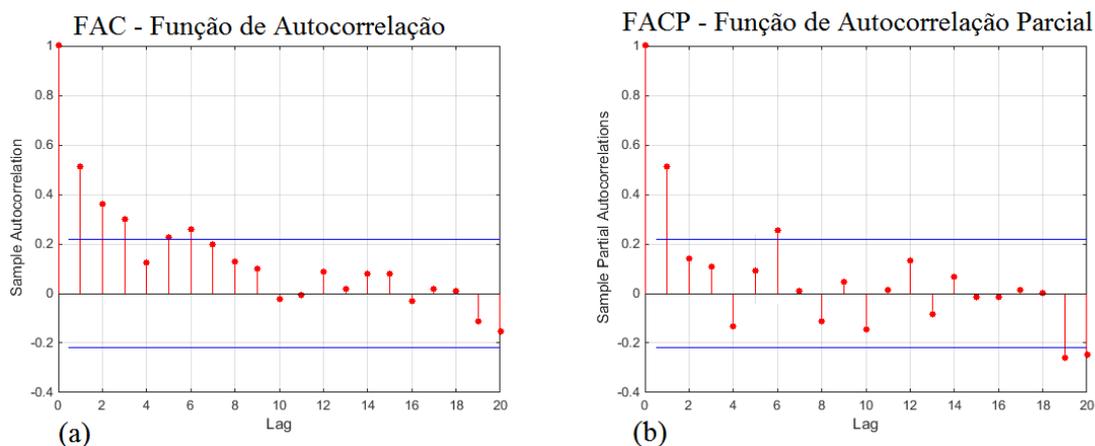
O próximo passo foi a escolha dos itens a serem utilizados. Como é apresentado na Figura 10, os consumos são dos mais diversificados possíveis e objetivou-se buscar itens que exemplifiquem modelos de evolução de demanda existentes, levando em consideração não apenas sua classificação quanto a curva ABC, mas também sua aplicação e a família a qual pertence, ou seja, funilaria, elétrica, estofamento, acabamento, motorização, suspensão e lubrificação uma vez que pretendia-se encontrar traços de obsolescência.

Alguns desses itens, ainda que de famílias diferentes, possuem uma mesma característica comercial, como é o caso dos itens que caracterizam o modelo do veículo, acabamento e grande parte da tapeçaria, podendo ser exemplificados por um mesmo produto sem perder a relevância na abrangência do estudo em questão.

Ao se analisar os gráficos da série temporal na Figura 10 pode-se extrair algumas informações preliminares sobre os itens selecionados do conjunto de observações estudado. Na Figura 10(a) nota-se que o item possui uma aparente estabilidade de consumo, enquanto que na Figura 10(b) o item tem uma tendência decrescente no consumo. As Figuras 10(c) e 10(d) apresentam itens que demonstram de forma inversa uma tendência, sendo o primeiro com tendência decrescente chegando ao ponto de não ser utilizado a partir do mês de setembro de 2010 e o segundo com tendência crescente, porém com comercialização a partir de outubro de 2010.

Nesses itens também foram analisadas as autocorrelações e autocorrelações parciais com o intuito de identificar tendências, sazonalidades e definir a quantidade de entrada com base na maior autocorrelação parcial. Por outro lado, optou-se por manter a quantidade de neurônios na entrada nunca menor do que quatro, pois, conforme apresentado por Mine (2010), em testes demonstrou-se ser de baixa eficiência quando se tem uma quantidade reduzida de neurônios na camada de entrada.

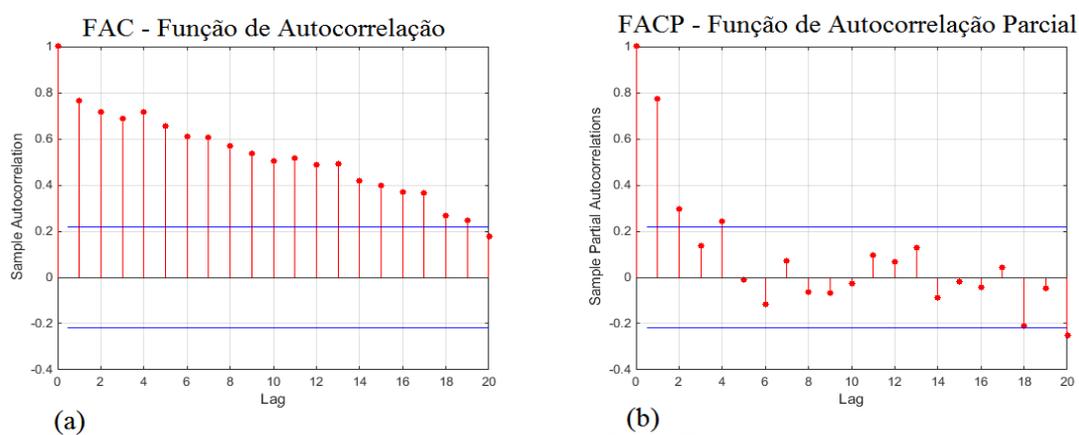
Figura 11 - Autocorrelação e autocorrelação parcial do anteparo dianteiro



Fonte: Elaborado pelo autor (2016)

O gráfico de autocorrelação (FAC) apresentado na Figura 11(a) referente ao item Anteparo Dianteiro revela a falta de comportamento senoidal, indicando que a série não possui sazonalidade. Já a autocorrelação parcial (FACP), Figura 11(b), não decai rapidamente para zero, indicando que a série não é estacionária, além de demonstrar que as melhores opções de quantidade de entrada é 6, 9 ou 20 neurônios. Porém preferiu-se determinar 6 neurônios na camada de entrada atendendo o que é apresentado por Mileski Júnior (2007).

Figura 12 - Autocorrelação e autocorrelação parcial da presilha do para choque

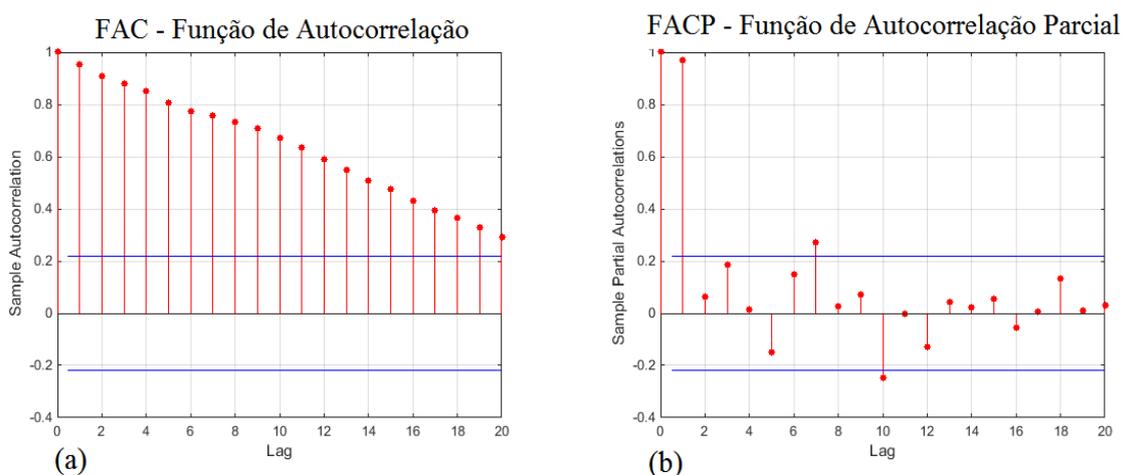


Fonte: Elaborado pelo autor (2016)

Na Figura 12(a) apresenta-se o gráfico de autocorrelação (FAC – Função de Autocorrelação) da Presilha do Para Choque, segundo item selecionado, para o qual pode-se notar a falta de sazonalidade, sendo que o gráfico da autocorrelação parcial indica que não é um item com demanda estacionária devido a não decair rapidamente para zero.

Conforme apresentado na figura 12(a), no FACP as quantidades de entrada na rede neural podem ser de 1, 2, 4 ou 20 neurônios na camada de entrada por terem as duas maiores correlações seguintes. Porém, conforme indicado por Mileski Júnior (2010), escolheu-se a utilização de 4 valores para compor a camada de entrada. O mesmo autor ainda relata que quanto maior for a quantidade de entradas utilizada, maior será a complexidade do problema a ser resolvido e muito maior será a quantidade de soluções possíveis para análise pela metodologia neural, o que implica no aumento do tempo de processamento ou na diminuição do espaço de soluções explorado. Assim sendo, escolheu-se para esse item a quantidade de entrada de 4 neurônios.

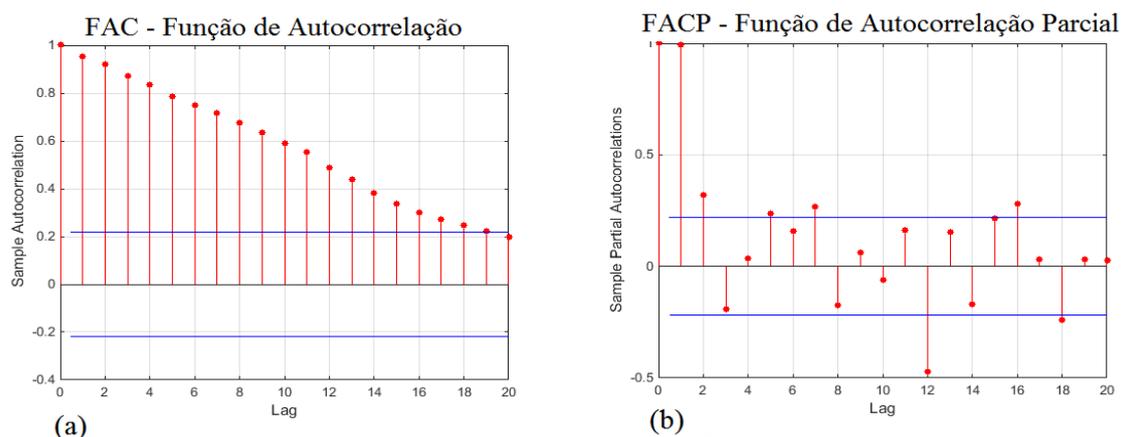
Figura 13 - Autocorrelação e autocorrelação parcial do tapete standart



Fonte: Elaborado pelo autor (2016)

A exemplo do item anterior, o tapete *standart* que é item de um modelo específico de veículo, também não demonstra sazonalidade ou demanda estacionária através da análise do FAC. De igual forma, o FACP indica que a melhores correlações para se definir a quantidade de neurônios na camada de entrada são 7 ou 10 neurônios, apesar de ter uma alta correlação com 1 entrada. De igual forma, optou-se pela menor quantidade, neste caso, 7 neurônios na camada de entrada.

Figura 14 - Autocorrelação e autocorrelação parcial do para choque traseiro



Fonte: Elaborado pelo autor (2016)

O para choque traseiro também é um item que define o modelo do veículo e na Figura 14(a) o FAC ilustra, a exemplo dos anteriores, a ausência de comportamento senoidal indicando não possuir sazonalidade. O FACP, apresentado na Figura 14(b), diferentemente dos anteriores, revela uma baixa correlação com 5, 7 e 16 entradas e que existe uma alta correlação para 1 ou 12 neurônios na camada de entrada, ficando assim definida em 12 a quantidade de neurônios na camada de entrada desse item.

4.2 Aplicação das Redes Neurais Artificiais

Um dos problemas enfrentados no treinamento de redes neurais diz respeito à definição de seus parâmetros. A seleção dos parâmetros de treinamento do algoritmo é um processo tão pouco compreendido, que é muitas vezes chamado de “caixa preta”. Pequenas diferenças nestes parâmetros podem levar a grandes diferenças tanto no tempo de treinamento como na generalização obtida.

Deve-se ter em mente que é preciso obter um modelo que não seja muito rígido a ponto de não modelar fielmente os dados, mas que também não seja excessivamente flexível a ponto de modelar também o ruído presente nos dados. A ideia é que a rede responda de acordo com as características presentes nos dados de entrada e não exatamente igual aos dados de entrada.

Desta forma, as redes neurais de Elman e *Time Delay Neural Network (TDNN)* foram criadas utilizando linhas de comando específicos, conforme apresentado nos Apêndices A e B. Cada rede teve uma configuração diferente levando em consideração sua estrutura e suas características próprias, porém todas com uma mesma estrutura de programação

possibilitando uma flexibilização maior.

A princípio, procurou-se trabalhar com a ferramenta *nntool* no Matlab® para treinar, validar e prever a demanda através da rede neural de Elman, mas a mesma demonstrou ser de pouca interatividade, ao contrário da programação através de comandos que, apesar de parecer mais complicada, propicia uma configuração mais detalhada permitindo alterações em alguns parâmetros que no *toolbox* não é possível.

A rede foi desenvolvida, para ser a mais autônoma possível, e a partir de uma matriz de entrada linear busca-se a autocorrelação parcial existente entre os valores para se definir a quantidade de neurônios na entrada. Com esse valor, o algoritmo refaz as matrizes que serão utilizadas como dados de treinamento, alvo do treinamento, dados de validação, alvos da validação e alvos da previsão da demanda.

Um fator que determina a qualidade e velocidade do treinamento da rede é a quantidade de neurônios na camada escondida. Se se utilizar de poucos neurônios na camada escondida, a rede neural é incapaz de modelar dados mais complexos, resultando em uma baixa capacidade de generalização (*underfitting*). Se muitos neurônios forem utilizados, o treinamento da rede irá se tornar excessivamente longo e a rede pode sofrer problemas de sobreajuste (*overfitting*) resultando na perda da capacidade preditiva da rede, pois observa-se pequenos desvios de previsão para os dados usados na fase de treino, mas grandes desvios quando novos dados de entrada são utilizados. Dados com ruídos ou redundantes podem provocar a falha da rede na convergência de uma solução genérica.

A quantidade de camadas também influencia os resultados. Porém, vários estudos (LIMA, 2014; MINE, 2010; PASQUOTO, 2010; GOMES, 2005) demonstram que para a maioria dos problemas, uma camada escondida é suficiente. Entretanto, se os dados contêm descontinuidades, uma camada escondida adicional auxilia na aproximação das funções de quaisquer tipos ou formas, o que torna desnecessária a utilização de uma quantidade maior de camadas ocultas.

A modelagem por redes neurais artificiais constituiu em estruturar duas arquiteturas distintas, para que fossem avaliadas entre si e selecionado o modelo que apresentasse os melhores resultados de previsão. As redes utilizadas foram a Rede de Elman e *Time Delay Neural Network* (TDNN), para cada um dos itens escolhidos e com três quantidades distintas de neurônios na camada escondida.

As 84 observações mensais serão divididas em 3 partes: conjunto de treinamento,

composto de 54 observações, o conjunto de validação com 18 observações e o conjunto de previsão com 12 observações.

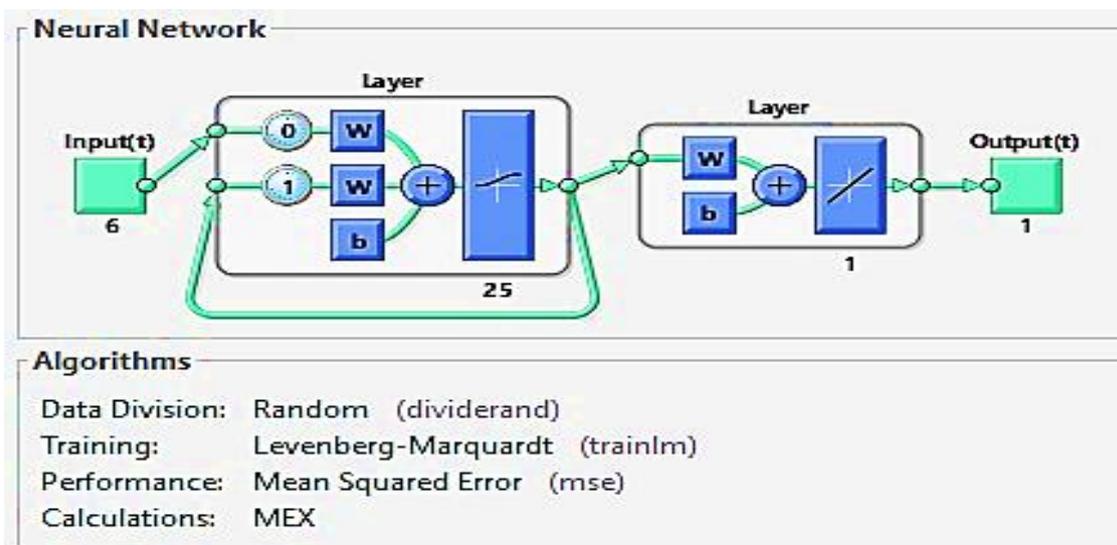
O treinamento das redes modeladas constituiu em apresentar à rede os pesos dos neurônios para que pudessem ser ajustados conforme o comportamento da série temporal e as características de cada rede estudada. Os critérios de parada foram definidos buscando encontrar o menor erro médio quadrático (MSE) da validação, mas ocorrendo 25 treinamentos para os quais o MSE não diminua ou atingindo as 1.000 iterações a rede finalizará o seu treinamento.

4.3 Rede de Elman

A rede de Elman foi escolhida por ser caracterizada como uma rede recorrente simples e a realimentação capacita a realização de tarefas que se estendem no tempo, sendo essa a principal característica que a diferencia, além da possibilidade de se introduzir várias camadas ocultas, cada qual com seus neurônios, suas funções de transferência, porém com um único algoritmo de aprendizagem. Outra característica é que a arquitetura dessa rede permite que os neurônios não dependam apenas dos valores de entrada, mas também desses valores defasados no tempo.

Na Figura 15 ilustra-se a rede de Elman com sua topologia, a quantidade de neurônios na camada de entrada, na camada oculta, o algoritmo de treinamento, e a medida de desempenho como sendo o erro médio quadrático.

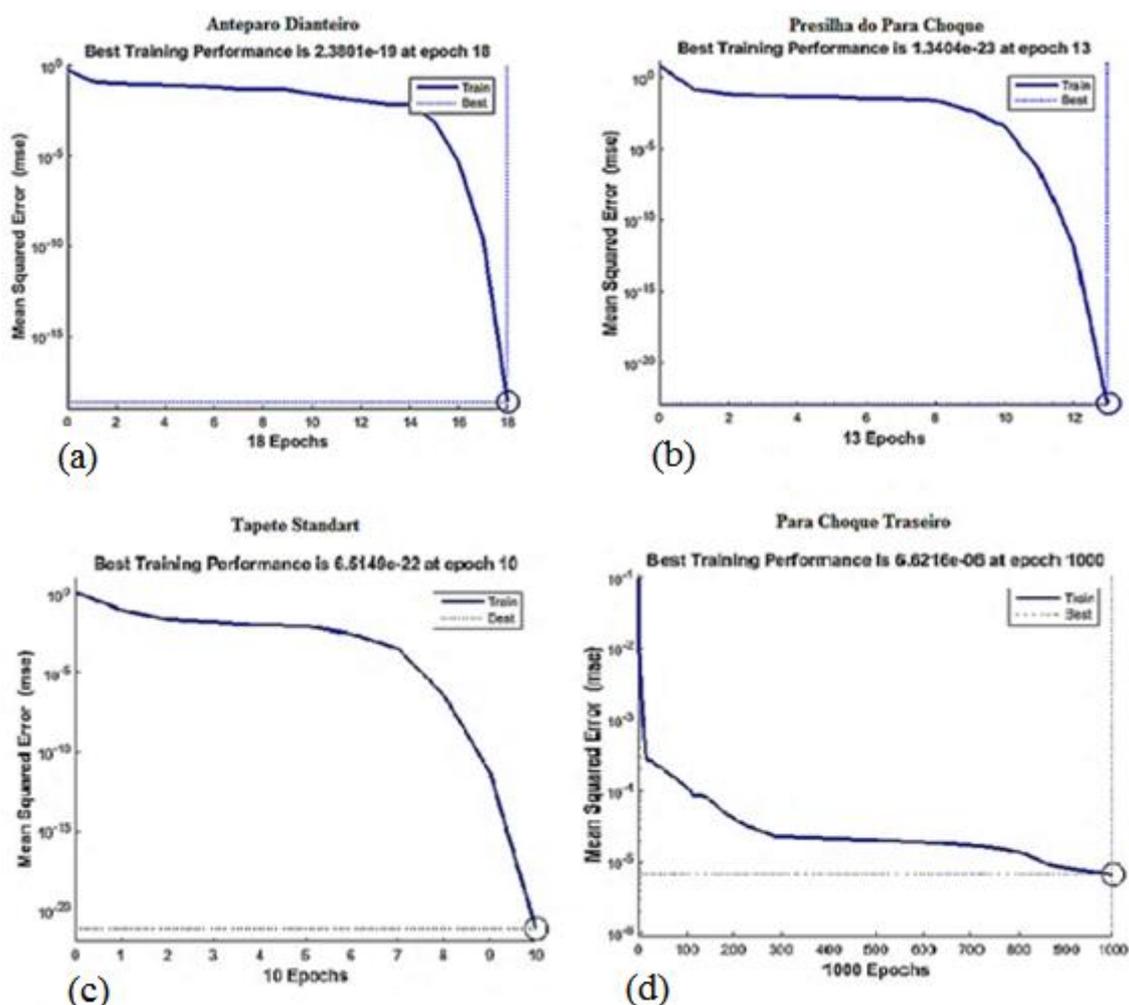
Figura 15 - Rede de Elman



Vários testes foram realizados para encontrar a configuração que melhor adaptasse às séries históricas. Após os testes iniciais, foi possível definir os seguintes parâmetros: uma camada oculta, número máximo de 1.000 iterações como critério de parada, taxa de aprendizado de 0,025, a função de transferência da primeira camada oculta é a *logsig* e utilizou-se o algoritmo de *Levenberg-Marquardt* (*trainlm*) e a função de adaptação de aprendizagem foi a *learnngdm*. O erro médio quadrático (MSE) foi utilizado como o critério para se definir o melhor resultado, pois quanto menor o MSE melhor o resultado da rede. Os pesos iniciais foram gerados de forma aleatória, o que possibilitou que a cada novo treinamento, a rede se adaptasse buscando resultados diferentes dos anteriores.

Apesar da limitação das 1.000 iterações por treinamento da rede, como pode-se notar na Figura 16, o erro médio quadrático decai e estabiliza bem próximo a zero com quantidades variadas em cada item apresentado.

Figura 16 - Performance do MSE na rede de Elman



Fonte: MATLAB R2014b (2016)

Os itens representados na Figura 16(a) e 16(b), mesmo com poucas interações, mostram que a rede de Elman conseguiu um resultado significativo, apresentando resultados melhores do que os apresentados pelo atual modelo que a empresa utiliza. Os itens 16(c) no treinamento atinge um MSE muito próximo de zero com apenas 10 interações, mas para o item 16(d), mesmo com um total de 1.000 iterações, não se consegue identificar o padrão da demanda, permanecendo com um erro médio quadrático na previsão de 0,3300 conforme apresentado na Tabela 3.

Tabela 3- Medidas de erro de previsão dos modelos da rede de Elman

ITEM	REDE	MSE Trein.	MSE Validação	MSE Previsão	MAPE Previsão	MSE Média Móvel	MAPE Média Móvel
Anteparo Dianteiro	Elman (6,15,1)	1,10e-27	0,3443	0,2141	0,4567	2,3333	0,1250
	Elman (6,20,1)	5,16e-25	0,3291	0,0868	0,2646		
	Elman (6,25,1)	6,65e-27	0,5917	0,0594	0,0706		
Presilha do Para Choque	Elman (4,15,1)	8,24e-24	0,0697	0,0475	0,2811	1,0837	0,1890
	Elman (4,20,1)	1,34e-23	0,0460	0,0790	0,3378		
	Elman (4,25,1)	5,71e-19	0,3965	0,0447	0,2567		
Tapete Standart	Elman (7,15,1)	4,98e-25	0,0034	0,1144	0,5177	0,0000	0,0000
	Elman (7,20,1)	9,20e-23	0,0354	0,0351	0,1955		
	Elman (7,25,1)	3,21e-22	0,0895	0,0122	0,0814		
Para Choque Traseiro	Elman (12,15,1)	2,72e-05	0,5163	1,5579	1,5644	1,0083	0,1408
	Elman (12,20,1)	1,04e-20	0,3102	2,6905	1,9748		
	Elman (12,25,1)	1,75e-05	0,6828	3,0311	2,8712		

Fonte: Elaborado pelo autor (2016)

As arquiteturas modeladas para cada item possuem as seguintes configurações, conforme apresentado na Tabela 3: Elman (A, B, C) representa redes de Elman com uma camada oculta, sendo A o número de neurônios na camada de entrada, B o número de neurônios na camada oculta e C é o número de neurônio na camada de saída.

Foram executados 2.500 testes, onde variou-se a quantidade de neurônios na camada oculta entre 1 e 30 neurônios e observou-se que os melhores resultados foram encontrados quando se trabalha com 15, 20 ou 25 neurônios nesta camada. Pelo exposto na Tabela 3, pode-se notar que existe uma variabilidade de resultados divergentes entre o número de neurônios na camada oculta, revelando que nem sempre a maior quantidade é necessariamente a melhor, aqui definido pelo MSE da previsão, o que indica que quanto menor o valor do erro médio quadrático melhor é o resultado da rede.

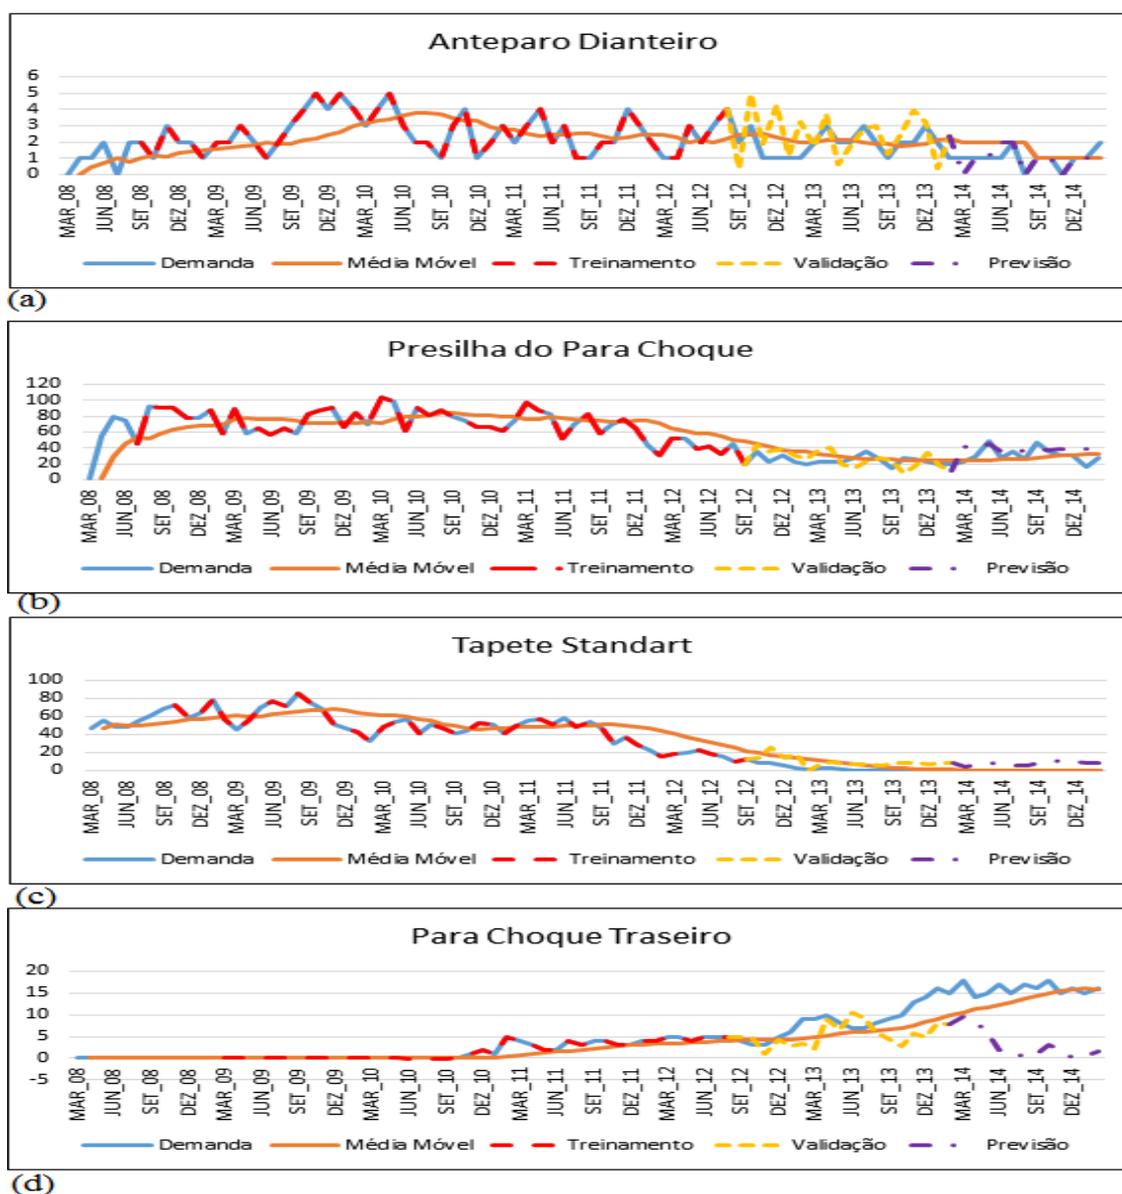
Considerando o menor erro médio quadrático, nota-se que com uma maior série histórica, a rede reage de forma melhor com quantidades maiores de neurônios na camada oculta. Por outro lado, itens novos ou com poucos dados mensais na série histórica conseguem melhor desempenho quando são trabalhados com quantidades menores de

neurônios na camada oculta. Outro fato que cabe observar é que as redes neurais necessitam de mais dados para identificar o padrão da demanda com uma acurácia maior.

Ao se analisar o resultado da rede com base nos valores apresentados pelo MAPE (*Mean Absolute Percent Error*), pode-se notar que ele segue a tendência do MSE, ou seja, quando o erro médio quadrático diminui, ele também diminui.

Todas as arquiteturas implementadas encontraram bons resultados para a previsão da série temporal quando comparado ao MSE da média móvel de 12 meses, que hoje é utilizada pela empresa. Para fins de inspeção visual, na Figura 17 está ilustrada uma comparação gráfica das previsões encontradas na rede neural de Elman e a média móvel.

Figura 17 – Previsões encontradas pela rede de Elman



Fonte: Elaborado pelo autor (2016)

Na Figura 17 estão dispostos os melhores resultados encontrados na previsão para 12 meses, nota-se que a rede de Elman não consegue identificar com clareza o padrão da demanda de todos os itens apresentados. Os melhores resultados foram obtidos com o item Anteparo Dianteiro, Figura 17(a) onde obteve-se um erro médio quadrático de 0,0594 e um MAPE de 0,0706 na previsão da demanda.

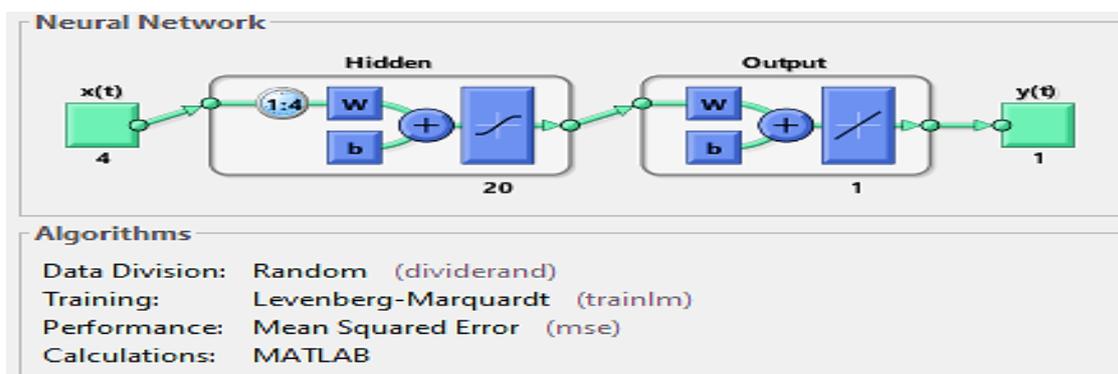
Se comparado ao que hoje é utilizado pela empresa sob estudo, o item apresentado na Figura 17(a) apresenta um ganho significativo na acurácia da previsão quando se considera o MSE ou o MAPE. Na média móvel, o MSE ficou em 2,3333 enquanto que, na Rede de Elman, o melhor resultado foi de 0,0594 e o MAPE da média móvel foi 0,1250 e na rede chegou a 0,0706, demonstrando que, em qualquer uma das duas medidas de desempenho escolhidas, a rede propicia um ganho na qualidade da previsão de demanda e conseqüentemente melhora a tomada de decisão quanto ao que comprar.

4.4 Rede Time Delay Neural Network - TDNN

No experimento com a rede TDNN foram realizados 2.500 testes variando o tempo de atraso, iniciando com o padrão de 1:2 e atingindo 24 meses de atrasos, ou seja 1:24. Nos testes, pode-se notar que ao se trabalhar com mais de uma entrada, aqui definida pela autocorrelação parcial, o melhor resultado ocorre quando o atraso é composto pela mesma medida. Assim sendo, o atraso será sempre igual à quantidade de entradas na rede.

Na Figura 18 ilustra-se a rede TDNN, apresentando sua topologia bem como a quantidade de entrada, o atraso da rede, a quantidade de neurônios na camada oculta, o algoritmo de treinamento, e a medida de desempenho como sendo o erro médio quadrático.

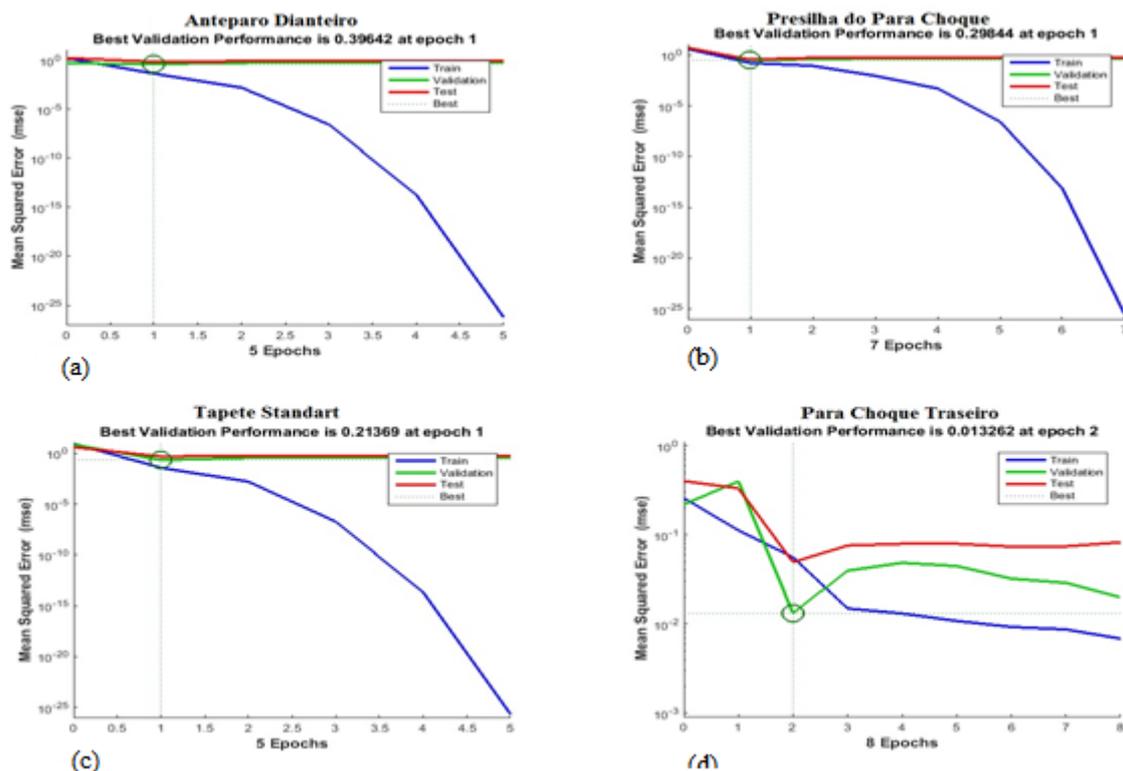
Figura 18 - Rede TDNN



Como é notado na Figura 18, o atraso é de 4 meses, a mesma quantidade de entrada e a função de transferência para a camada de saída utilizada é a *Tan-Sigmoid*, enquanto que a função de transferência para o neurônio de saída é a *Pureline*.

Tal qual ocorre na rede de Elman, apesar da limitação das 1.000 iterações, os valores do erro médio quadrático tendem a se aproximar muito rapidamente do zero no treinamento da rede. Isso pode ser notado ao se observar a Figura 19.

Figura 19 - Performance do MSE na rede TDNN



Fonte: MATLAB R2014b (2016)

Com exceção do item Para Choque Traseiro representado na figura 19(d) que não apresentou diminuição do erro médio quadrático na mesma velocidade que os demais, todos os três outros itens conseguiram atingir valores muito próximos de zero com poucas iterações da rede na fase de treinamento.

As arquiteturas modeladas para cada item possuem as seguintes configurações, conforme apresentado na tabela 4: TDNN (A, B, C, D) representam redes TDNN com uma camada oculta, sendo A o número de neurônios na camada de entrada, B o atraso da rede, C número de neurônios na camada oculta e D é o número de neurônios na camada de saída.

Tabela 4 - Medidas de Erro de Previsão dos Modelos da Rede TDNN

ITEM	REDE	MSE Trein.	MSE Validação	MSE Previsão	MAPE Previsão	MSE Média Móvel	MAPE Média Móvel
Anteparo Dianteiro	TDNN (6,6,15,1)	1,04e-19	0,2643	0,3439	0,9167	2,3333	0,1250
	TDNN (6,6,20,1)	0,0815	0,2858	0,4833	1,0072		
	TDNN (6,6,25,1)	0,1066	0,3329	0,1517	0,5250		
Presilha do Para Choque	TDNN (4,4,15,1)	5,28e-22	0,5753	0,0340	0,4801	1,0837	0,1890
	TDNN (4,4,20,1)	1,07e-17	0,0341	0,0301	0,2422		
	TDNN (4,4,25,1)	5,73e-24	0,4476	0,0450	0,3047		
Tapete Standart	TDNN (7,7,15,1)	1,21e-22	0,3431	0,4675	0,7257	0,0000	0,0000
	TDNN (7,7,20,1)	1,10e-15	2,2030	0,4201	0,6776		
	TDNN (7,7,25,1)	3,91e-26	0,3906	0,6465	0,7455		
Para Choque Traseiro	TDNN (12,12,15,1)	9,90e-03	0,9425	3,3415	2,3038	1,0083	0,1408
	TDNN (12,12,20,1)	4,84e-02	0,3916	2,2767	1,9044		
	TDNN (12,12,25,1)	8,23e-02	0,6474	0,8954	1,1979		

Fonte: Elaborado pelo autor (2016)

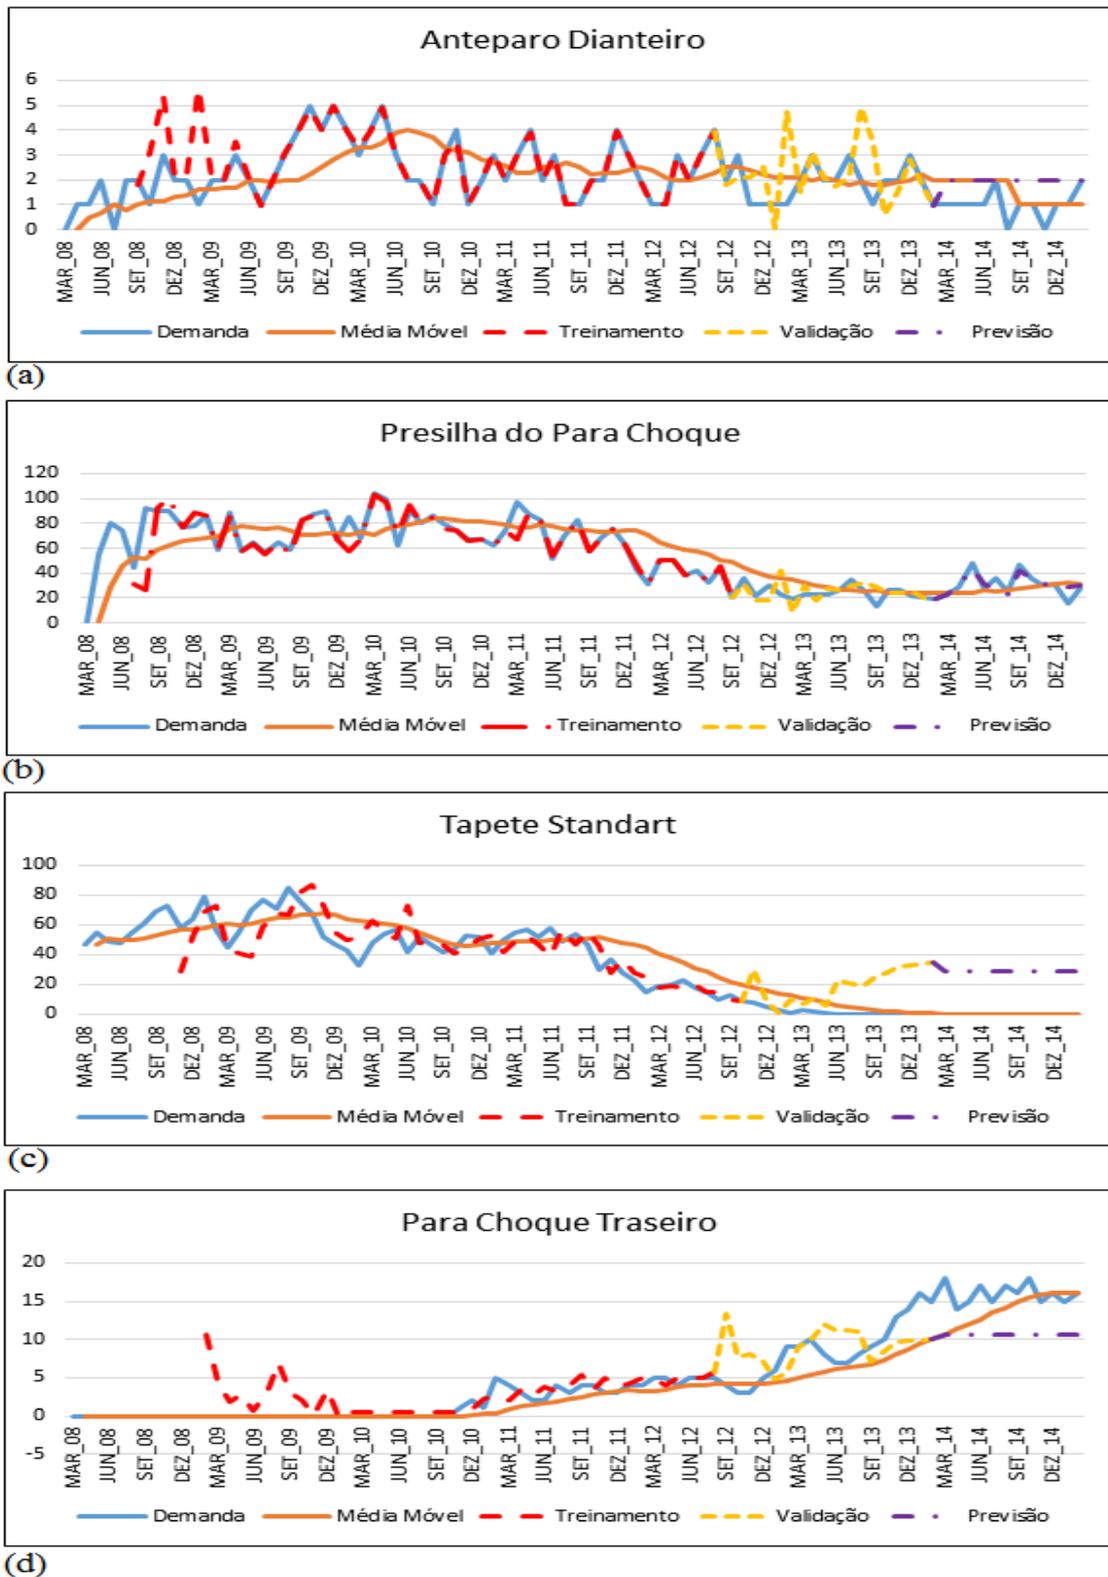
Nos 2.500 testes executados, além de analisar o tratamento do atraso, variou-se a quantidade de neurônios na camada oculta entre 1 e 30 neurônios, obtendo-se os melhores resultados com 15, 20 e 25 neurônios.

Pelo descrito na Tabela 4, existe uma variabilidade de resultados quando se altera a quantidade de neurônios na camada oculta. Vale ressaltar que o fato de aumentar a quantidade de neurônios não resultará, necessariamente, em melhoria do reconhecimento de padrão e consequente diminuição do erro médio quadrático ou do MAPE.

A rede TDNN adaptou-se melhor ao item Presilha do Para Choque, chegando a um erro médio quadrático na previsão de 0,0301 muito inferior ao erro de 1,0837 apresentado pela média móvel aritmética que é o método utilizado atualmente pela empresa. Porém, quando se compara com o MAPE, a rede TDNN teve um pior resultado do que a média móvel, 0,2422 da rede e 0,1890 da média móvel.

Na Figura 20 são apresentados os gráficos das demandas dos quatro itens analisados com os respectivos resultados da rede TDNN quanto a treinamento, validação e previsão bem como a média móvel aritmética de 12 meses.

Figura 20- Previsões encontradas pela rede TDNN



Fonte: Elaborado pelo autor (2016)

Observando a Figura 20, onde estão dispostos os melhores resultados encontrados na previsão para 12 meses, nota-se que a rede TDNN também não consegue se adaptar a todos os padrões de demanda. Os melhores resultados foram obtidos com o item Presilha

do Para Choque, Figura 20(b), onde obteve-se um erro médio quadrático de 0,0301 e um MAPE de 0,2422 na previsão da demanda.

Pelo gráfico obtém-se uma visualização mais detalhada e clara da adaptabilidade da rede TDNN ao item representado na Figura 20(b), sendo que em algumas previsões a rede chega a exatamente a mesma quantidade demandada e mesmo onde não se atinge tal assertividade, os valores se aproximam bastante do real no período, o que demonstra de forma clara a superioridade da rede TDNN em comparação com o modelo atualmente em uso na empresa.

4.5 Gráfico comparativo das redes

Ao comparar as previsões feitas com o emprego das duas redes, Elman e TDNN, nota-se claramente, conforme apresentado na Tabela 5, que a rede de Elman se sobressai em relação a TDNN, porém sem grande eficácia nos itens Tapete Standart e Para Choque Traseiro.

Tabela 5 - Medidas de Erro de Previsão dos Modelos da Rede de Elman e TDNN

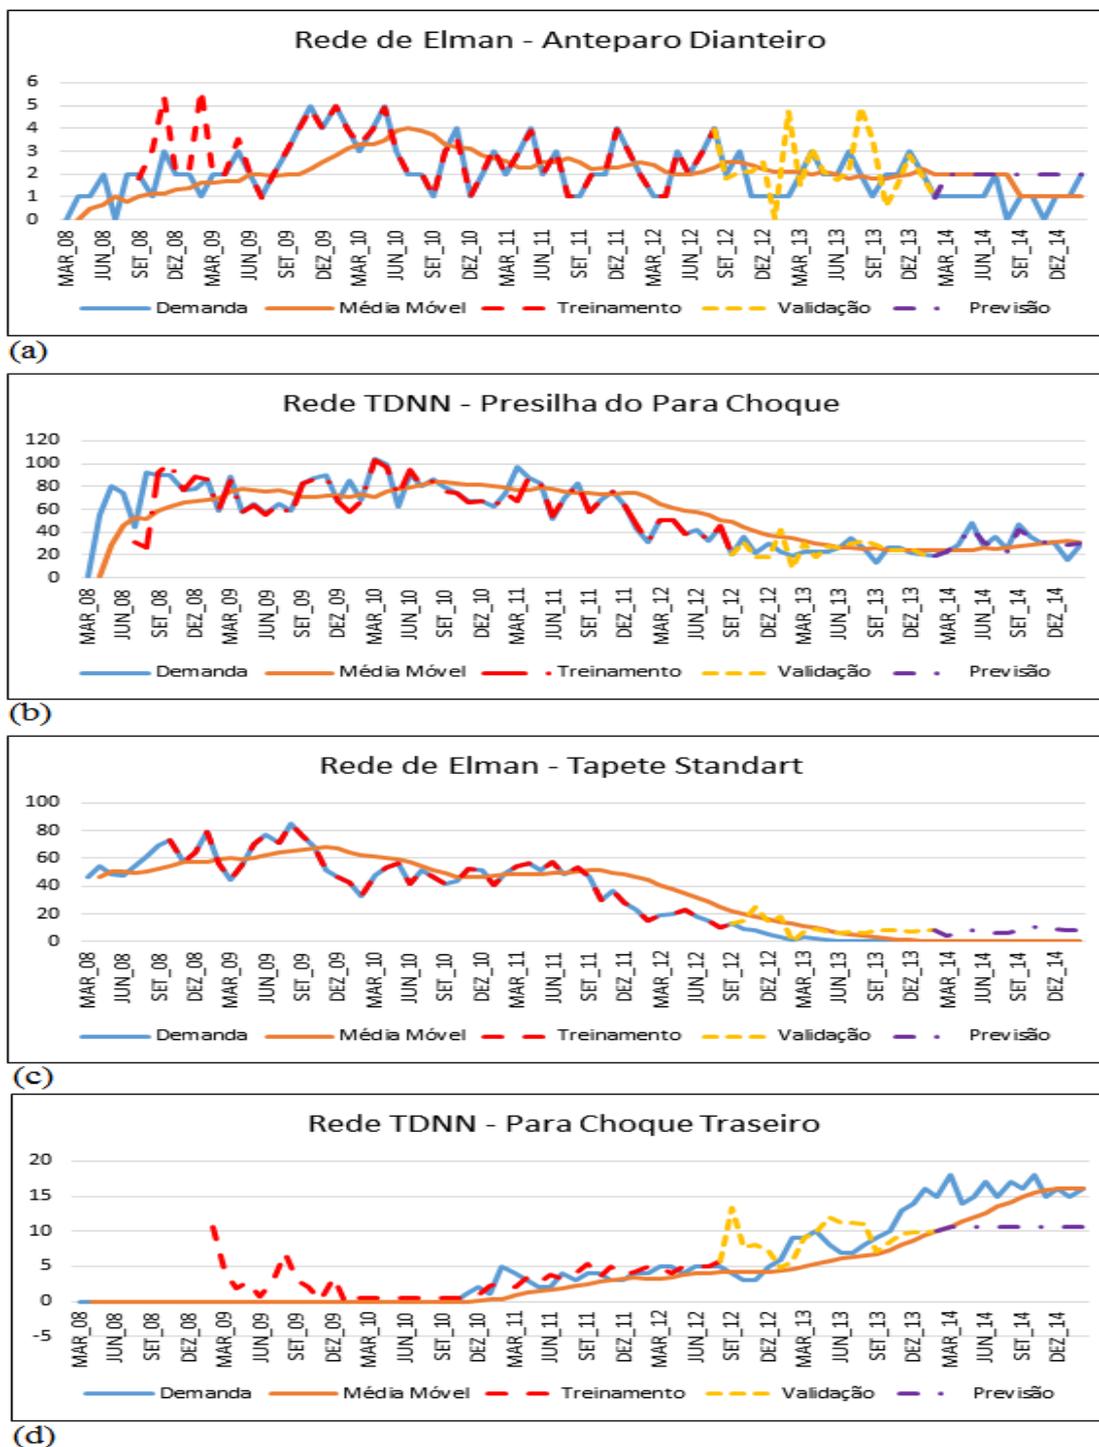
ITEM	REDE	MSE Trein.	MSE Validação	MSE Previsão	MAPE Previsão	MSE Média Móvel	MAPE Média Móvel
Anteparo Dianteiro	Elman (6,25,1)	6,65e-27	0,5917	0,0594	0,0706	2,3333	0,1250
	TDNN (6,6,25,1)	0,1066	0,3329	0,1517	0,5250		
Presilha do Para Choque	Elman (4,25,1)	5,71e-19	0,3965	0,0447	0,2567	1,0837	0,1890
	TDNN (4,4,20,1)	1,07e-17	0,0341	0,0301	0,2422		
Tapete Standart	Elman (7,25,1)	3,21e-22	0,0895	0,0122	0,0814	0,0000	0,0000
	TDNN (7,7,20,1)	1,10e-15	2,2030	0,4201	0,6776		
Para Choque Traseiro	Elman (12,15,1)	2,72e-05	0,5163	1,5579	1,5644	1,0083	0,1408
	TDNN (12,12,25,1)	8,23e-02	0,6474	0,8954	1,1979		

Fonte: Elaborado pelo autor (2016)

Na Tabela 5 observa-se que a rede de Elman atingiu um menor erro médio quadrático em três dos quatro itens, enquanto a rede TDNN conseguiu ser melhor no item Presilha do Para Choque. Se a comparação for feita quanto ao MAPE, cada uma das redes obteve melhores resultados em dois dos quatro itens. Quanto aos itens Tapete Standart e Para Choque Traseiro, as duas redes foram menos eficientes perdendo inclusive para a média móvel.

Na Figura 21 pode-se notar com mais clareza os gráficos das demandas dos quatro itens analisados com os respectivos resultados da rede de Elman e TDNN quanto a treinamento, validação e previsão, bem como a média móvel aritmética de 12 meses.

Figura 21 - Comparativo das previsões encontradas pela rede de Elman e TDNN



Fonte: Elaborado pelo autor (2016)

Ao analisar a Figura 21(a) e a Figura 21(b), os itens demonstram que as redes convergem melhor para a demanda real e os itens da Figura 21(c) e Figura 21(d), devido

à introdução de valores nulos no início ou no final da série histórica para complementar os 84 meses.

4.6 Reavaliação dos períodos de inatividade

Os itens apresentados na Figura 21(c) e na Figura 21(d) tem como peculiaridade o fato de não possuírem as 84 séries históricas como os outros dois primeiros itens. O item Tapete *Standart*, Figura 21(c), deixou de ser comercializado a partir de junho de 2013 o que faz com que tenha 64 observações. O item Para Choque Traseiro, Figura 21(d), só começou sua comercialização em novembro de 2010, fazendo com que tenha 52 observações em sua série histórica. Isso ocorre devido a variações do modelo e ao ciclo de vida cada vez mais reduzido do produto, confirmando o que foi abordado na seção 2.1.

Para que todos os itens fossem submetidos aos mesmos critérios de testes que os demais, preferiu-se atribuir demanda zero para esses períodos de inatividade o que, como pode ser observado a seguir, ocasionou em perda de rendimento por parte das redes trabalhadas.

Ao se retirar os períodos de inatividade, todos os indicadores que definem a quantidade de neurônios na camada de entrada, o tempo de atraso na rede TDNN bem como o MSE e o MAPE da média móvel atualmente utilizada pela empresa, devem ser recalculados, e o período destinado para a previsão continua sendo 12 meses. Após o recálculo de tais indicadores e treinamento das redes chegou-se ao resultado apresentado na Tabela 6.

Tabela 6- Avaliação da rede de Elman e TDNN após retirada de períodos de inatividade

ITEM	REDE	MSE Trein.	MSE Validação	MSE Previsão	MAPE Previsão	MSE Média Móvel	MAPE Média Móvel
Tapete Standart	Elman (7,25,1)	5,38e-13	0,0363	0,0354	0,7714	0,0486	0,8110
	TDNN (7,7,20,1)	5,92e-09	0,2125	0,4372	0,8632		
Para Choque Traseiro	Elman (12,15,1)	8,56e-18	0,0873	0,4387	0,8153	1,0083	0,9068
	TDNN (12,12,25,1)	5,00e-18	0,4074	0,0385	0,2705		

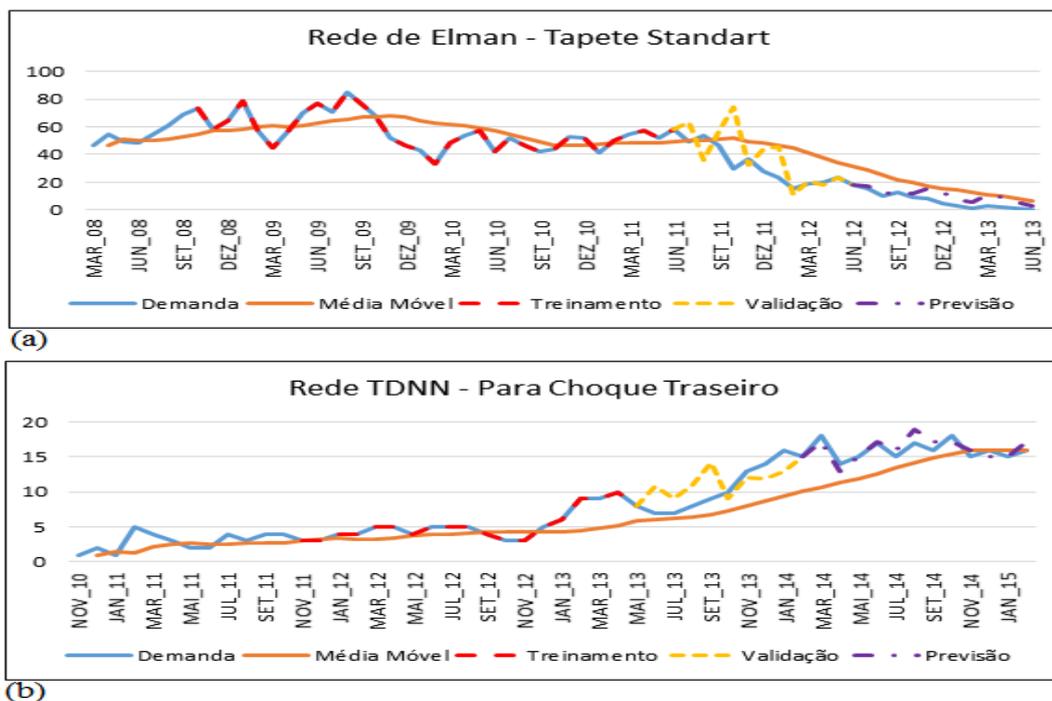
Fonte: Elaborado pelo autor (2016)

Ao analisar a Tabela 6, observa-se que a rede Elman conseguiu melhores resultados em um item e a TDNN em outro, e se comparado com a Tabela 5. Nota-se que os indicadores melhoraram devido ao MSE e o MAPE da previsão serem menores após a retirada dos períodos de inatividade do item, o que de certa forma contraria a premissa de

treinamento das redes neurais, que determina que uma quantidade maior de dados leva a um melhor reconhecimento dos padrões. Vale ressaltar que os dados que completavam os 84 meses eram irreais.

Para uma melhor compreensão dos resultados obtidos, na Figura 22 encontram-se os gráficos de evolução de consumo das melhores redes de cada item ilustrando que a previsão se aproximou bastante da demanda real e comprovando o apresentado na Tabela 6 onde no primeiro item a rede de Elman chegou a um MSE de 0,0354 frente a 0,0486 da média móvel e o MAPE de 0,7714 ante os 0,8110 da média. No segundo item, a Rede TDNN conseguiu um MSE de 0,0385 e na média móvel 1,0083, já o MAPE chegou a 0,2705 ante os 0,9068 do método atual utilizado pela empresa.

Figura 22 - Comparativo das redes de Elman e TDNN após retirada de períodos de inatividade



Fonte: Elaborado pelo autor (2016)

Na Figura 22(a), ao ser comparada com a Figura 21(c), pode-se notar com mais facilidade o que foi evidenciado também pela Tabela 6, na qual a previsão de demanda oriunda do resultado da rede neural artificial aproxima-se de forma significativa da real demanda dos últimos 12 meses do item. O mesmo ocorre na Figura 22(b), quando comparada à Figura 21(d).

Quanto ao tempo de processamento e a quantidade de iterações ocorridas em ambos os casos nada se modificou, permanecendo inalterados os resultados conforme apresentados no início deste capítulo.

5 CONCLUSÕES

A utilização de métodos de previsão de demanda pela empresa pesquisada, ainda que atualmente não sejam eficientes, ressalta a preocupação com a otimização do processo de gestão dos estoques. No entanto, para se alcançar um padrão aceitável, as organizações devem destinar especial atenção ao grau de acurácia do método preditivo e a adoção de sistemas de monitoramento dos erros de previsão. Este último aspecto é importante para a tomada de ações corretivas, quando necessário.

Esta pesquisa buscou estudar e implementar duas redes neurais, Elman e TDNN, com o intuito de averiguar sua eficácia quanto à previsão de demandas de peças de reposição de veículos automotores como fonte de opção com um nível maior de acurácia em referência ao que é utilizado atualmente pela empresa pesquisada.

Neste sentido, após a análise das redes TDNN e Elman consegue-se concluir que as redes com as configurações apresentadas têm grande potencial para se tornarem não só uma opção a mais, mas uma realidade que auxiliará na condução correta da gestão de estoques em uma empresa que trabalha com alta rotatividade de modelos o que a obriga a rever constantemente seus estoques.

Outro fator de extrema importância é que ao se conseguir determinar as necessidades demandadas com 12 meses de antecedência e com a acurácia demonstrada pelas RNA's, pode-se utilizar tais valores na averiguação de futuras obsolescências decorrentes da diminuição do volume de vendas nos próximos meses. Tal processo reduziria significativamente o nível de estoque, eliminando grande parte das perdas oriundas de itens obsoletos que devem ser descartados por falta de procura.

Além dessas observações, nota-se também que algumas redes se adaptaram melhor a determinado tipo de gráfico de evolução de consumo como a Elman que consegue resultados melhores em demandas cuja evolução seja constante e a TDNN que se adaptou melhor a itens que estejam em evolução de tendência crescente ou decrescente.

Apesar da complexidade na parametrização da rede, em decorrência das diversas possibilidades de combinações de parâmetros, pode-se afirmar que as redes neurais artificiais estudadas são viáveis dentro do escopo deste trabalho, conseguindo a partir dos resultados chegar ao objetivo proposto inicialmente.

A sugestão para trabalhos futuros é a aplicação de variáveis exógenas para composição das entradas das redes neurais, tais como quantidade de veículos vendidos

em períodos anteriores e a renda per capita que pode influenciar na melhor manutenção dos veículos e conseqüente aumento da demanda de peças de reposição, confrontando os resultados com os obtidos neste estudo.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ABELÉM, A. J. G. **Redes Neurais Artificiais na Previsão de Séries Temporais.** (Mestrado), Departamento de Engenharia Elétrica, PUC-RJ, Rio de Janeiro, 1994.

ADYA, M., COLLOPY, F. **How Effective Are Neural Networks at Forecasting and Prediction? A Review and Evaluation.** *Journal Forecast.* v. 17, p. 481–495, 1998.

ANDRADE, L. N. **Redes Neurais Artificiais Aplicadas na Identificação Automática de Áreas Cafeeiras em Imagem de Satélite.** (Mestrado), Programa de Pós-Graduação do Departamento de Ciências da Computação, Universidade Federal de Minas Gerais (UFMG), 2011.

ARAÚJO, B. C. e GOMES H.M. **Redes Neurais Versus Métodos Estatísticos na Previsão de Séries Temporais.** (Mestrado), Universidade Federal de Campina Grande, Departamento de Sistemas e Computação, 2005.

ARMSTRONG, J. **Selecting Forecasting Methods.** In: ARMSTRONG, J. **Principles of Forecasting: A Handbook for Researchers and Practitioners.** Boston: Kluwer Academic Publishers, 2001.

BARRETO, J. M. **Inteligência Artificial: No limiar do século XXI.** Florianópolis, Duplic, 2a. ed., 2000.

BERRY, M. J. A., LINOFF, G. **Data Mining Techniques For Marketing, sales and customer support.** 1st ed. [S.I.] John Wiley e Sons, 1997.

BRANCO, S.T., SAMPAIO, R.J.B. **Aplicação de Redes Neurais Artificiais em Modelos de Previsão de Demanda Para Equipamentos de Infra-Estrutura de Telecomunicações.** XXVIII Encontro Nacional de Engenharia de Produção, Rio de Janeiro-RJ, 13 a 16 de outubro de 2008.

BUKKAPATNAM, S.T.S.; AKKARAPOL, S.; KIM J.; IYER P.; SURESH, R.P. **Multi-step sales forecasting in automotive industry based on structural relationship identification**. International Journal of Production Economics v.2, p.875-887, 2012

CASTRO, M.C.F. **Predição Não-Linear de Séries Temporais Usando Redes Neurais RBF por Decomposição em Componentes Principais**. (Doutorado), Faculdade de Engenharia Elétrica e Computação, UNICAMP, Campinas, 2001.

CHARU, A; YU, A.P. **Outlier Detection for High Dimensional Data**, 2001.

DIAS, M.A.P; **Administração de Materiais: Princípios, Conceitos e Gestão**. 5ª ed., São Paulo, Atlas, 2005.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**, 2. ed. New York: J Wiley, 2001.

ELMAN, J.L. **Distributed Representations, Simple Recurrent Networks and Grammatical Structure**. Machine Learning, v. 7, p. 195-225, 1991.

ESTRELLA, A., MISHKIN, F.S.; **Predicting U.S. Recessions: Financial Variables as Leading Indicators**. Rev. Econ. Stat., v. 80, p. 45–61, 1998.

FERNANDES, A.M.R., “**Inteligência Artificial: Noções Gerais**”, Florianópolis: Bookstore, 2003.

FIGUEREDO, C. J. **Previsão de Séries Temporais Utilizando a Metodologia Box-Jenkins e Redes Neurais Para Inicialização de Planejamento e Controle de Produção**. (Mestrado), Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná, Curitiba, 2008.

FIORIN, D.V.; MARTINS, F.R.; SCHUCH, N.J.; PEREIRA, E.B. **Aplicações de Redes Neurais e Previsões de Disponibilidade de Recursos Energéticos Solares**. Revista Brasileira de Ensino de Física, v. 33, n. 1, p.1309, 2011.

FREEMAN, J. A. SKAPURA, D. M.; **Neural Networks: Algorithms, Applications and Programming Techniques**. Addison-Wesley Publishing, 1992

FREITAS, F. D. **Modelo de Seleção de Carteiras Baseado em Erros de Predição**. (Doutorado) – UFES Universidade Federal do Espírito Santo, Vitória, ES, 2008.

GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. São Paulo: Atlas, 1995.

GOMES, D. T. **Redes Neurais Recorrentes Para Previsão de Séries Temporais de Memórias Curta e Longa**. (Mestrado), Instituto de Matemática, Estatística e Computação Científica, UNICAMP, Campinas, 2005.

GONÇALVES, P.S., **Administração de Materiais**, 2ª ed., Rio de Janeiro: Elsevier, 2007.

GUARNIERI, R.A.. **Emprego de Redes Neurais Artificiais e Regressão Linear Múltiplas no Refinamento das Previsões de Radiação Solar do Modelo Eta**. (Mestrado), INPE, São José dos Campos, 2006, 120 p.

HAIR, J; BLACK, W; BABIN, B; ANDERSON, R. **Multivariate data analysis**. 7th ed., Prentice-Hall, Inc. Upper Saddle River, NJ, USA, 2010.

HAYKIN, S. **Neural Networks and Learning Machines**. 3º. ed. New Jersey: Prentice Hall, 2009.

HILL, T.; O CONNOR, M.; REMUS, W. **Neural Network Models for Time Series Forecasts**. Management Science, v.42, n.7, p.1082-1092, Jul 1996.

KIM, H.; SHIN, K.; **A Hybrid Approach Based on Neural Networks and Genetic Algorithms For Detecting Temporal Patterns in Stock Markets**. Applied Soft Computing, [S.L.], v. 7, n. 2, p.569-576, 2007.

KOHONEN, T. **Self-Organization and Associative Memory**. Springer-Verlag, Berlin, 1987.

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

LAKATOS, E.M.; MARCONI, M.A. **Fundamentos de Metodologia Científica**. 3ª ed. ver. e ampl. São Paulo: Atlas, 1996.

LIMA, R.R.D. **Análise Comparativa de Previsão Por Meio de Modelos Econométricos e Redes Neurais**. (Mestrado) Pós-Graduação em Engenharia da Produção e Sistemas – Pontifícia Universidade Católica de Goiás – Goiânia, 2014.

LINDBERG, E; ZACKRISSON, U. **Deciding About The Uncertain: The Use of Forecast as an Aid to Decision-Making**. Scandinavian Journal of Management. V. 7, n. 4, p. 271-283, 1991

LOPES, R. D. **Previsão de Autopeças: Estudo de Caso em uma Concessionária de Veículos**. (Mestrado) — UFSC Universidade Federal de Santa Catarina, Florianópolis, SC, 2002.

MAKRIDAKIS, S.G.; WHEELWRIGHT, S.C. **Forecasting: Issues & Challenges for Marketing Management**. Journal of Marketing, v.41, n.4, p.24-38, 1977.

MARTINS, P.G., CAMPOS, P.R.; **Administração de Recursos Materiais e Patrimoniais**. 2ª ed., São Paulo: Ed. Saraiva, 2006.

MARTINS, P.G., LAUGENI, F.P.; **Administração da Produção** 2ª ed. rev. aum. e atual. São Paulo. Saraiva, 2006.

MCCULLOCH, W.S.; PITTS, W. **A Logical Calculus of the Ideas Immanent in Nervous Activity**. Bulletin of Mathematical Biophysics 5 (1943), 115-133

MENEZES JUNIOR, J.M.P; BARRETO, G.A.; **Extensões da Rede Recorrente de ELMAN Para Predição Não-Linear de Séries Temporais Caóticas: Um estudo comparativo**. 10ª Conferência Brasileira de Dinâmica, Águas de Lindóia - SP, 2011

MILESKI JÚNIOR, A. **Análise de Métodos de Previsão de Demanda Baseados em Séries Temporais em Uma Empresa do Setor de Perfumes e Cosméticos.** (Mestrado) — PUC, Pontifícia Universidade Católica, Curitiba, PR, 2007.

MINE, O.M.; **Previsão de Demanda de Autopeças com Redes Neurais** (Mestrado) Pós Graduação em Ciência da Computação – Universidade Federal do Espírito Santo – Vitória, 2010.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons: an Introduction to Computational Geometry.** The MIT Press, Massachusetts, 1969

MOHD, K. B. A. H. **Multiple Faults Detection Using Artificial Neural Network.** 2004. p. 177. (Doutorado) - Faculty of Chemical and Natural Resources Engineering, Universiti Teknologi Malaysia, Malaysia, 2004.

MOON, M.; MENTZER, J.; SMITH, C.; GARVER, M. **Seven Keys to Better Forecasting.** Business Horizons, v.41, n. 5, p. 44-52, 1998.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais.** Editora Edgard Blücher Ltda. São Paulo-SP, 2004.

MUELLER, A. **Uma Aplicação de Redes Neurais Artificiais na Previsão do Mercado Acionário.** (Mestrado), Programa de Pós-Graduação em Engenharia de Produção - UFSC, Florianópolis, 1996.

OLIVEIRA, M.A., FÁVERO, L.P.L. **Uma Breve Descrição de Algumas Técnicas Para Análise de Séries Temporais: Séries de Fourier, Wavelets, ARIMA, Modelos Estruturais Para Séries de Tempo e Redes Neurais.** VI Semead: Ensaio de MQI. 2003

OSBORNE, Jason W.; OVERBAY, Amy. **The power of outliers and why researchers should always check for them.** Practical Assessment. Research & Evaluation, v. 9, n. 6, 2004.

PARDOE, I. **Applied Regression Modeling: A Business Approach**. Hoboken, NJ: Wiley, 2006.

PARKER, D. **Learning logic**. Invention Report S81-64, File 1, Once of Technology Licensing, Stanford University, 1982.

PASQUOTTO, J.L.D. **Previsão de Redes Temporais no Varejo Brasileiro: Uma Investigação Comparativa da Aplicação de Redes Neurais Recorrentes de Elman**. (Mestrado) Pós-Graduação em Administração – Universidade de São Paulo – USP – São Paulo, 2010.

POZZO, H.; **Administração de Recursos Materiais e Patrimoniais: uma abordagem logística**. 3ª ed. São Paulo: Atlas, 2004.

PRECHELT, L. **Early Stopping – But When? Neural Networks: Tricks of the Trade**, Lecture Notes in Computer Science, v. 7700, p. 53-67, 2012.

QIAN, X. Y., LIU, Y. M., JIANG, Z. Q., PODOBNIK, B., ZHOU, W. X., STANLEY, H. E. (2015). **Detrended partial cross-correlation analysis of two nonstationary time series influenced by common external forces**. Physical Review E, v. 91, n. 6, p. 062816, 2015.

RAO, C., ALI, J. **Neural Network Model for Database Marketing In The New Global Economy**. Marketing Intelligence and Planning, v.20, n.1, p. 35-43, 2002

RITZMAN, L.; KRAJEWSKI, L. **Administração da Produção e Operações**. Practice Hall, São Paulo – SP, 2004.

ROISENBERG, M. **Emergência da Inteligência em Agentes Autônomos através de Modelos Inspirados na Natureza**. (Doutorado), Departamento de Engenharia Elétrica, Grupo de Pesquisas em Engenharia Biomédica, UFSC, 1998.

ROITMAN, V. L. **Um Modelo Computacional de Redes Neurais Para Predição do Índice de Desemprego Aberto**. (Doutorado), Programa de Pós-Graduação em Engenharia da Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

ROLIM, F.G.; **Como Transformar Peças de Reposição em Dinheiro na Mão**. São Paulo: Rolim Consult, 2001.

RUMELHART, D. E., MCCLELLAND J. L., and PDP Group. **Parallel Distributed Processing**, v. 1, Foundations. The MIT Press, Cambridge, Massachusetts, 1986.

SCHATZ, C.H.V; **Sistema Inteligente Para Monitoramento e Predição do Estado Clínico de Pacientes Baseado em Lógica Fuzzy e Redes Neurais**. (Doutorado), Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica do Paraná; Curitiba, 2014.

SILVA, C.S., **Previsão Multivariada da Demanda Horária de Água em Sistemas Urbanos de Abastecimento**. (Doutorado), Pós-Graduação da Universidade Estadual de Campinas – Faculdade de Engenharia Civil, 2003

SILVA, I. N., SPATTI, D. H. e FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**, 1ª ed, São Paulo: Artliber, 2010.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da Produção**. 3. ed., São Paulo: Atlas, 2009.

SONG, Z., FU, Z., WANG, H.; HOU, G. **Demand Forecasting Model of Port Critical Spare Parts**. Institute of Advanced Engineering and Science. Telkomnika Indonesian Journal of Electrical Engineering, Vol.12, No. 5, Maio de 2014, pp. 3483 ~ 3490

SWANSON, N.R., WHITE, H., **Forecasting Economic Time Series Using Flexible Versus Fixed Specification and Linear Versus Nonlinear Econometric Models**. Int. J. Forecast. v. 13, p. 439–461, 1997

TAYLOR, D.A., **Logística na Cadeia de Suprimentos: Uma Perspectiva Gerencial**. São Paulo: Pearson, 2005.

UOL ECONOMIA, Redução de IPI Para Carros Termina e Imposto Fica Maior a Partir do Dia 1º. Disponível na URL: <<http://economia.uol.com.br/noticias/redacao/2014/12/>

31/reducao-de-ipi-para-carros-termina-e-imposto-fica-maior-a-partir-de-amanha.htm>.
Acesso em 15/09/2015.

YIN, R. **Estudo de Caso. Planejamento e Métodos**. 2ª edição, Porto Alegre/RS: Bookman, 2001.

VALE, A. A. M.; CARVALHO, D. C. O.; MADRUGA, M. R. **Modelos Sazonais Aplicados a Série de Exportação de Bens**. XI Escola de Modelos de Regressão, Recife, PE, 2009.

VAZ, A.G.C.R; **Photovoltaic Forecasting With Artificial Neural Networks**. (Mestrado) Programa de Pós-Graduação Integrado em Engenharia da Energia e Ambiente – Universidade de Lisboa – Portugal, 2014.

VERGARA, S. C. **Projetos e Relatórios de Pesquisa em Administração**. 7 ed. São Paulo: Atlas, 2006.

VIGLIONI, G. M. C. **Metodologia Para Previsão de Demanda Ferroviária Utilizando Data Mining**. (Mestrado) Pós-Graduação em Engenharia de Produção — IME, Instituto Militar de Engenharia, Rio de Janeiro, 2007.

VOSS, C; TSIKRIKTSIS, N; FROHLICH, M. **Case Research in Operations Management**. *International Journal of Operations & Production Management*, v. 22, n. 2, p. 195-219, 2002.

WAIBEL, A.; HANAZAWA, T.; HINTON, G., SHIKANO, K. e LANG, K. (1989). **Phonemic Recognition Using Time Delay Neural Networks**, *IEEE Trans. Acoust. Speech, Signal Processing* 37(3): 328–339.

WERBOS, P. J. **Beyond Regression: New Tools for Prediction and Analysis in the Behavioral sciences**. (Thesis), Harvard University, Cambridge, MA, 1974.

WHIGTH, S.F., UPADHYAYA, A. **Extraction of an abundant and unusual protein from soil and comparison with hyphal protein of arbuscular mycorrhizal fungi.** Soil Science, v.161, p. 575–586, 1996.

ZOUCAS, F.A.M.; **Aplicação de Redes Neurais Para Previsão de Séries Temporais em Segmentos Industriais.** (Mestrado em Engenharia Mecânica), Centro Universitário da FEI, São Bernardo do Campo – SP, 2009.

APÊNDICE A – CÓDIGO MATLAB DA REDE DE ELMAN

```

clc;
clear all;
%Matriz com as Demandas - Anteparo Dianteiro
%demanda_inicial=[0 1 1 2 0 2 2 1 3 2 2 1 2 2 3 2 1 2 3 4 5 4
5 4 3 4 5 3 2 2 1 3 4 1 2 3 2 3 4 2 3 1 1 2 2 4 3 2 1 1
3 2 3 4 2 3 1 1 1 1 2 3 2 2 3 2 1 2 2 3 2 1 1 1 1 1 2 0
1 1 0 1 1 2];

%Matriz com as Demandas - Presilha do Para Choque
%demanda_inicial=[2 55 80 75 45 93 90 90 77 78 87 59 89 58 65 56 65 59
83 88 90 67 85 69 104 99 62 91 81 87 79 75 67 67 62 75 97 88 83 52 70
83 58 69 76 64 43 31 51 51 38 42 32 45 20 36 22 30 23 19 23 23 23 27
35 25 14 27 26 22 20 19 23 29 48 28 36 25 47 36 30 31 16 28];

%Matriz com as Demandas - Tapete Standard
%demanda_inicial=[47 55 49 48 55 61 69 73 58 64 79 57 45 56 70 77 71 85
76 68 52 47 43 33 48 54 57 42 52 47 42 44 53 52 41 50 55 57 52 58 49
54 47 30 37 28 23 15 19 20 23 18 15 10 13 9 8 5 3 1 3 2 1 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0];

%Matriz com as Demandas -Para Choque Traseiro
%demanda_inicial=[0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 1 2 1 5 4 3 2 2 4 3 4 4 3 3 4 4 5 5
4 5 5 5 4 3 3 5 6 9 9 10 8 7 7 8 9 10 13 14 16 15 18 14 15 17
15 17 16 18 15 16 15 16];

%Matriz com as Demandas - Tapete Standard - modificado
demanda_inicial=[47 55 49 48 55 61 69 73 58 64 79 57 45 56 70 77 71 85 76
68 52 47 43 33 48 54 57 42 52 47 42 44 53 52 41 50 55 57 52 58 49 54
47 30 37 28 23 15 19 20 23 18 15 10 13 9 8 5 3 1 3 2 1 0];

%Matriz com as Demandas -Para Choque Traseiro - modificado
%demanda_inicial=[1 2 1 5 4 3 2 2 4 3 4 4 3 3 4 4 5 5 4 5 5 5
4 3 3 5 6 9 9 10 8 7 7 8 9 10 13 14 16 15 18 14 15 17 15 17 16
18 15 16 15 16];

%Especificidades da Rede de Elman
h=12; % tamanho do intervalo que será feita a previsão
emax = 1000; % máximo de épocas, limitado pelo "early stopping"
vmax = 25; % máximo de vezes que se permite aumentar o erro na validação 25
alfa = 0.025;% taxa de aprendizado

%da demanda total retira o periodo que servira para previsão posterior
[demanda_total, PS] = mapminmax(demanda_inicial);
demanda=demanda_total(1:(end-h));
tamanho = length(demanda); % Defini o tamanho da matriz demanda

%verifica a autocorrelação das variaveis na matriz demanda para definir a
%quantidade de entradas na rede

```

```

a = autocorr(demanda_total);
autocorr(demanda_total) % mostra o gráfico da autocorrelação
acf=int8(max(a))

% verifica a autocorrelação parcial das variáveis da matriz de demanda
a = parcorr(demanda_total);
parcorr(demanda_total) %mostra o gráfico da autocorrelação parcial
pacf=int8(max(a))

auto_c = 7

s1 = 25; % número de neurônios na 1a. camada oculta
%s2 = 15; % número de neurônios na 2a. camada oculta
%s3 = 5; % número de neurônios na 3a. camada oculta

tf1 = 'logsig'; %função de transferência 1a. camada oculta pode ser logsig purelin ou
tansig
%tf2 = 'logsig'; %função de transferência 2a. camada oculta
%tf3 = 'logsig'; %funcao de transferência 3a. camada oculta
btf = 'trainlm'; %algoritmo de treinamento da rede - pode ser trainbdf, trainbr,
traincgb, traincgf, traingd, traingdm, traingda, traingdx, trainlm, trainoss, trainr, trainrp,
trainscg
blf = 'learnngdm'; %função de aprendizagem adaptação - pode ser learnngd e learnngdm
pf = 'mse'; %função de performance - pode ser mse, msereg ou sse

%define qual tamanho da matriz demanda sera usada para treinamento e para
%validação da rede (75% treinamento + 25% validacao)
tam_tre = (tamanho * 0.75); %% qtd de meses utilizados para montar a matriz de
treinamento
tam_val = (tamanho * 0.25); %% qtd de meses utilizados para montar a matriz de
validação (simulação)

%monta a matraiz de entrada e de alvo a partir do tamanho de valiação e de
%treinamento considerando a autocorrelação entre os dados.

% Matriz de entada para treinamento
col = (tam_tre - (auto_c-1));
a=0;
for l=1:auto_c
    for c=1:col
        a=(a+1);
        Entrada_T(l,c) = demanda(1,a);
    end
    a=l;
end

%matriz alvo de treinamento
Alvo_T = demanda((auto_c+1):(tam_tre+1));

% Validação da rede

```

```

% Matriz de entrada para validação
col1 = (tam_val - (auto_c - 1));
a = (tam_tre - (auto_c - 1));

l=0;
for l=1:auto_c
    for c=1:tam_val
        a=(a+1);
        Entrada_V(l,c) = demanda(1,a);
    end
    a = (tam_tre - (auto_c - 1)) + 1;
end

%alvo da validação
alvo_valid = demanda((tam_tre + 1):end);

%criar a rede de elman
net=newelm(Entrada_T,Alvo_T, [s1], {tf1}, btf, blf, pf); % com 1 camada oculta
%net=newelm(Entrada_T,Alvo_T, [s1, s2], {tf1, tf2}, btf, blf, pf); % com 2 camadas
ocultas
%net=newelm(Entrada_T,Alvo_T, [s1, s2, s3], {tf1, tf2, tf3}, btf, blf, pf); % com 3
camadas ocultas
%net = elmannet(1:8,s1);

%taxa de apredizado
net.trainParam.lr = alfa;

%prepara matriz para treinamento e validação da rede
pseq=con2seq(Entrada_T); % con2seq transforma o vetor convencional em vetor
sequencial
tseq=con2seq(Alvo_T);
pvseq=con2seq(Entrada_V);

epoca = 0;
falhavalidacao = 0;
mse_vant = 0;
pesoI = 0;
mse_vant = 9999;
net.trainParam.epochs = 1000; % Default = 1000
while (epoca <= emax) && (falhavalidacao < vmax);
    epoca = (epoca + 1)
    [net,TR]=train(net, pseq, tseq);
    net.trainParam.showWindow = false;

    y=sim(net, pvseq); %% Validação ou Simulação da rede
    z = seq2con(y);
    valida=(z{1,1}(1:end));
    errovalid = (alvo_valid - valida); %calcula o erro da validação
    mse_valid = mse(errovalid); %erro mse da validação (erro médio quadrático)
    if (mse_valid < mse_vant)

```

```

    mse_valid
    mse_vant
    falhavalidacao = 0; %zera o contador quando o erro diminui
    mse_vant = mse_valid;
    pesoI = net.IW;
    pesoL = net.LW;
    pesoB = net.b;
else
    falhavalidacao = (falhavalidacao + 1) %soma o contador quando o erro aumenta
end
end
end

%ao finalizar pega o último peso e retorna para as variáveis da rede
net.IW = pesoI;
net.LW = pesoL;
net.b = pesoB;

y=sim(net, pseq);
z = seq2con(y);
treina=(z{1,1}(1:end));
errotreina = (Alvo_T-treina); %calcula o erro da validação
mse_treina = mse(errotreina); %erro mse da validação (erro médio quadrático)

%monta a matriz para fazer a previsão
demanda_prev=demanda_total((end-(h+auto_c-1)):end-h));
Alvo_P = demanda_total(((end-h)+1):end); %Alvo da previsão usado para calcular o
mse da previsão
tam_prev = length(demanda_prev); % Defini o tamanho da matriz demanda

% Matriz de entrada para previsão
col_p = (tam_prev - (auto_c - 1));
%a=0;
a= (tamanho-(auto_c));
for l=1:auto_c
    for c=1:col_p
        a=(a+1);
        Entrada_Prev(l,c) = demanda_total(1,a); % fazer a transversa resolveria
    end
    a= (tamanho-(auto_c))+1;
end
Prevseq = con2seq(Entrada_Prev);
y = sim(net,Prevseq);
z = seq2con(y);
prev = cell2mat(z);

% faz a previsão para os demais pontos
for i=1:h
    demanda_prev = [demanda_prev prev(end)];
    tam_prev = length(demanda_prev);
    % Refaz a Matriz de entrada incluindo a última previsão

```

```
a=(tam_prev - (auto_c-1));
for l=1:auto_c
    Entrada_Prev(l,1) = demanda_prev(1,a);
    a=(a+1);
end
Prevseq = con2seq(Entrada_Prev);
y3 = sim(net, Prevseq);
z3 = seq2con(y3);
prev=cell2mat(z3);
end
previsao = demanda_prev(end-(h-1):end);

mse_treina
mse_valid
%calcula MSe da previsao
erroprev = (previsao-Alvo_P); %calcula o erro da validação
mse_prev = mse(erroprev) %erro mse da validacao (erro mdio quadrático)
mape_prev= mean(abs(erroprev/Alvo_P))
clear a;

a1_treina = mapminmax('reverse', treina, PS);
a2_valida = mapminmax('reverse', valida, PS);
a3_previsao = mapminmax('reverse', previsao, PS);
```

APÊNDICE B – CÓDIGO MATLAB DA REDE TDNN

```

clc;
clear all;
%Matriz com as Demandas - Anteparo Dianteiro
%demanda_inicial=[0 1 1 2 0 2 2 1 3 2 2 1 2 2 3 2 1 2 3 4 5 4
5 4 3 4 5 3 2 2 1 3 4 1 2 3 2 3 4 2 3 1 1 2 2 4 3 2 1 1
3 2 3 4 2 3 1 1 1 1 2 3 2 2 3 2 1 2 2 3 2 1 1 1 1 1 2 0
1 1 0 1 1 2];

%Matriz com as Demandas - Presilha do Para Choque
%demanda_inicial=[2 55 80 75 45 93 90 90 77 78 87 59 89 58 65 56 65 59
83 88 90 67 85 69 104 99 62 91 81 87 79 75 67 67 62 75 97 88 83 52 70
83 58 69 76 64 43 31 51 51 38 42 32 45 20 36 22 30 23 19 23 23 23 27
35 25 14 27 26 22 20 19 23 29 48 28 36 25 47 36 30 31 16 28];

%Matriz com as Demandas - Tapete Standard
%demanda_inicial=[47 55 49 48 55 61 69 73 58 64 79 57 45 56 70 77 71 85
76 68 52 47 43 33 48 54 57 42 52 47 42 44 53 52 41 50 55 57 52 58 49
54 47 30 37 28 23 15 19 20 23 18 15 10 13 9 8 5 3 1 3 2 1 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0];

%Matriz com as Demandas -Para Choque Traseiro
%demanda_inicial=[0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 1 2 1 5 4 3 2 2 4 3 4 4 3 3 4 4 5 5
4 5 5 5 4 3 3 5 6 9 9 10 8 7 7 8 9 10 13 14 16 15 18 14 15 17
15 17 16 18 15 16 15 16];

%Matriz com as Demandas - Tapete Standard - modificado
demanda_inicial=[47 55 49 48 55 61 69 73 58 64 79 57 45 56 70 77 71 85 76
68 52 47 43 33 48 54 57 42 52 47 42 44 53 52 41 50 55 57 52 58 49 54
47 30 37 28 23 15 19 20 23 18 15 10 13 9 8 5 3 1 3 2 1 0];

%Matriz com as Demandas -Para Choque Traseiro - modificado
%demanda_inicial=[1 2 1 5 4 3 2 2 4 3 4 4 3 3 4 4 5 5 4 5 5 5
4 3 3 5 6 9 9 10 8 7 7 8 9 10 13 14 16 15 18 14 15 17 15 17 16
18 15 16 15 16];

%Especificidades da Rede TDNN
h=12; % tamanho do intervalo que será feita a previsão
emax = 1000; % máximo de épocas, limitado pelo "early stopping"
vmax = 25; % máximo de vezes que se permite aumentar o erro na validação
alfa = 0.025;% taxa de aprendizado

auto_c = 7; % qtd de entradas
atraso = 7;
s1 = 15; % número de neurônios na camada oculta

%da demanda total retira o período que servirá para previsão posterior
[demanda_total, PS] = mapminmax(demanda_inicial);
demanda=demanda_total(1:(end-h));

```

```

tamanho = length(demanda); % Defini o tamanho da matriz demanda

%define qual tamanho da matriz demanda sera usada para treinamento e para
%validação da rede (75% treinamento + 25% validação)
tam_tre = (tamanho * 0.75); %% qtd de meses utilizados para montar a matriz de
treinamento
tam_val = (tamanho * 0.25); %% qtd de meses utilizados para montar a matriz de
validação (simulação)

%verifica a autocorrelação das variáveis na matriz demanda para definir a
%quantidade de entradas na rede
a = xcorr(demanda_inicial);
auto_correlacao=int8(max(a))

%monta a matriz de entrada e de alvo a partir do tamanho de validação e de
%treinamento considerando a autocorrelação entre os dados.

% Matriz de entrada para treinamento
col = (tam_tre - (auto_c-1));
a=0;
for l=1:auto_c
    for c=1:col
        a=(a+1);
        Entrada_T(l,c) = demanda(1,a);
    end
    a=l;
end

%matriz alvo de treinamento
Alvo_T = demanda((auto_c+1):(tam_tre+1));

% Validação da rede
% Matriz de entrada para validação
col1 = (tam_val - (auto_c -1));
a= (tam_tre-(auto_c-1));

l=0;
for l=1:auto_c
    for c=1:tam_val
        a=(a+1);
        Entrada_V(l,c) = demanda(1,a);
    end
    a= (tam_tre-(auto_c-1))+l;
end

%alvo da validação
alvo_valid= demanda((tam_tre+1):end);

```

```

%prepara matriz para treinamento e validação da rede
pseq=con2seq(Entrada_T); % con2seq transforma o vetor convencional em vetor
sequencial
tseq=con2seq(Alvo_T);
pvseq=con2seq(Entrada_V);

%criar a rede TDNN
net = timedelaynet(1:atraso,s1); % atraso de 2 meses
[Xs,Xi,Ai,Ts] = preparets(net,pseq,tseq);

%ajuste de pesos com gradiente
net.trainFcn= 'trainlm'; %% Lanvenberg-Marquardt

%funcao de transferência
%net.transFcn = 'LOGSIG';

%algoritmo de treinamento = GBTT
%net.gradientFcn = 'calcgbtt';

%taxa de apredizado
net.trainParam.lr = alfa;

epoca = 0;
falhavalidacao = 0;
mse_vant = 0;
mse_vant = 9999;
net.trainParam.epochs = 100; % Default = 1000
while (epoca <= emax) && (falhavalidacao < vmax);
    epoca = (epoca + 1)
    net = train(net,Xs,Ts,Xi,Ai);
    net.trainParam.showWindow = false;

    % Y = net(Xs,Xi,Ai);
    %perf = perform(net,Ts,Y)
    %z=seq2con(Y);
    %y2= z{1,1}
    y=sim(net, pvseq); %% Validação ou Simulação da rede

    z = seq2con(y);
    valida=(z{1,1}(1:end));
    errovalid = (alvo_valid-valida); %calcula o erro da validação
    mse_valid = mse(errovalid); %erro mse da validação (erro médio quadrático)
    %if (epoca > 1) && (mse_valid > mse_vant),
    if (mse_valid < mse_vant)
        mse_valid
        mse_vant
        falhavalidacao = 0; %zera o contador quando o erro diminui
        mse_vant = mse_valid;
        pesoI = net.IW;
        pesoL = net.LW;

```

```

    pesoB = net.b;
else
    falhavalidacao = (falhavalidacao + 1) %soma o contador quando o erro aumenta
end
end

%ao finalizar pega o último peso e retorna para as variáveis da rede
net.IW = pesoI;
net.LW = pesoL;
net.b = pesoB;

y=sim(net, pseq);
z = seq2con(y);
treina=(z{1,1}(1:end));
errotreina = (Alvo_T-treina); %calcula o erro da validação
mse_treina = mse(errotreina); %erro mse da validação (erro médio quadrático)

%monta a matriz para fazer a previsão
% h = nr. de meses que ira fazer a previsão.... Declarada no início
demanda_prev=demanda_total((end-(h+auto_c-1):(end-h)));
Alvo_P = demanda_total(((end-h)+1):end); %Alvo da previsão usado para calcular o
mse da previsão
tam_prev = length(demanda_prev); % Defini o tamanho da matriz demanda

% Matriz de entrada para previsão

col_p = (tam_prev - (auto_c - 1));
%a=0;
a= (tamanho-(auto_c));
for l=1:auto_c
    for c=1:col_p
        a=(a+1);
        Entrada_Prev(l,c) = demanda_total(1,a); % fazer a transversa resolveria
    end
    a= (tamanho-(auto_c))+l;
end
Prevseq = con2seq(Entrada_Prev);
y = sim(net,Prevseq);
z = seq2con(y);
prev = cell2mat(z);

% faz a previsão para os demais pontos
for i=1:h
    demanda_prev = [demanda_prev prev(end)];
    tam_prev = length(demanda_prev);
    % Refaz a Matriz de entrada incluindo a última previsão
    %col = (tamanho - (auto_c - 1));
    a=(tam_prev - (auto_c-1));
    for l=1:auto_c
        Entrada_Prev(l,1) = demanda_prev(1,a);
    end
end

```

```
    a=(a+1);
end
Prevseq = con2seq(Entrada_Prev);
y3      = sim(net, Prevseq);
z3      = seq2con(y3);
prev=cell2mat(z3);
end
previsao = demanda_prev(end-(h-1):end);

%calcula MSe da previsão
erroprev = (previsao-Alvo_P); %calcula o erro da validação
mse_prev = mse(erroprev); %erro mse da validação (erro médio quadrático)
mape_prev= mean(abs(erroprev/Alvo_P));
clear a;

[demanda_total, PS] = mapminmax(demanda_inicial);

a1_treina    = mapminmax('reverse', treina, PS);
a2_valida    = mapminmax('reverse', valida, PS);
a3_previsao  = mapminmax('reverse', previsao, PS);

% Apresenta os resultados obtidos
mse_treina
mse_valid
mse_prev
mape_prev
```