

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE ENGENHARIA DE PRODUÇÃO
ENGENHARIA DE PRODUÇÃO**

LUCAS GONÇALVES MARTINS DE ALMEIDA

**MULTI-LAYER PERCEPTRON PARA PREVISÃO DE DEMANDA
DO SETOR AUTOMOBILÍSTICO NO BRASIL**

TRABALHO DE CONCLUSÃO DE CURSO

**PONTA GROSSA
2018**

LUCAS GONÇALVES MARTINS DE ALMEIDA

**MULTI-LAYER PERCEPTRON PARA PREVISÃO DE DEMANDA
DO SETOR AUTOMOBILÍSTICO NO BRASIL**

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel, em Engenharia de Produção, do Departamento Acadêmico de Engenharia de Produção, da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Me. Eng^a. José Jair Alves Mendes Junior

PONTA GROSSA

2018

	<p>Ministério da Educação UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ CÂMPUS PONTA GROSSA Departamento Acadêmico de Engenharia de Produção</p>	
---	---	---

TERMO DE APROVAÇÃO DE TCC

MULTI-LAYER PERCEPTRON PARA PREVISÃO DE DEMANDA DO SETOR
AUTOMOBILÍSTICO NO BRASIL

por

Lucas Gonçalves Martins de Almeida

Este Trabalho de Conclusão de Curso (TCC) foi apresentado em 30 de novembro de 2018 como requisito parcial para a obtenção do título de Bacharel em Engenharia de Produção. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Me. Eng^a. José Jair Alves Mendes Junior
Prof. Orientador

Prof. Dr. Max Mauro Dias Santos
Membro titular

Prof. Dr. Sergio Luiz Stevan Junior
Membro titular

“A Folha de Aprovação assinada encontra-se na Coordenação do Curso”.

AGRADECIMENTOS

Primeiramente à Deus, pela saúde, condição e possibilidade de ser livre para ir atrás dos meus sonhos.

Aos meus pais, Cybele e Paulo, e à minha família, que sempre demonstraram muito afeto e carinho por mim, me deram todo o apoio psicológico, emocional, financeiro, e foram minha base para crescimento pessoal e profissional.

Aos amigos de Ponta Grossa – aqui, em especial, aos donos do apartamento que residi por mais de quatro anos, os amigos que dividi o apartamento, e ao Grupo Panela – pelos momentos inesquecíveis que passamos juntos e por terem sido minha companhia durante a vida acadêmica.

Aos amigos de Santos e São José dos Campos, por sempre se fazerem presentes mesmo estando longe, por todo o apoio e carinho que sempre demonstraram. Em especial, à minha namorada, Júlia, pela paciência, companheirismo, incentivo, e por todo dia me fazer querer ser uma pessoa melhor para mim e às pessoas que estão à minha volta.

À Universidade Tecnológica Federal do Paraná, seu corpo docente, e em especial ao meu orientador Prof. José Jair, por todo o apoio e total condição de estrutura que me proporcionaram realizar o sonho de estudar e me formar em engenharia. Agradeço também ao ex-ministro da Educação, Fernando Haddad, o qual, através de programas sociais, possibilitou à mim e à muitos jovens a oportunidade de estudar em uma universidade pública de qualidade, ou até mesmo em outros países.

Por fim, à todos que de alguma forma contribuíram para a realização deste trabalho.

RESUMO

ALMEIDA, Lucas Gonçalves Martins de. **Multi-Layer Perceptron para previsão de demanda do setor automobilístico no Brasil**. 2018. 59 f. Trabalho de Conclusão de Curso Bacharelado em Engenharia de Produção - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2018.

Sabe-se que para as empresas é fundamental tentar prever o que acontecerá num futuro próximo se tratando de mercado, para que as mesmas possam ter condições de se prepararem e tomarem as devidas decisões em tempo hábil. As previsões podem ser dos mais variados tipos como a de demanda, de venda, de compra, de produção, de variação de mercado, variação de inflação, de estoque, entre outras. É muito importante que as empresas consigam obter essas informações com boa exatidão, ou seja, com menor desvio possível da realidade, para o sucesso num mercado tão competitivo como o atual. Muitas empresas utilizam as mais variadas formas para obtenção desses tipos de variáveis, e como a tecnologia avança em ritmo acelerado, cada vez mais se tem utilizado as Inteligências Artificiais (IAs). Redes Neurais Artificiais (RNAs) são um tipo de IA na qual sua utilização vem crescendo de forma consistente, onde se inspira no funcionamento do cérebro humano. As RNAs trabalham de forma semelhante, onde tentam reconhecer padrões e regularidades e são capazes de aprender através de treinamento, acumular conhecimento (experiência) e fazer generalizações. O intuito desse trabalho é verificar a eficiência da RNA de arquitetura de Multi-Layer Perceptron (MLP) na previsão de demanda de veículos automotores no Brasil. Utilizou-se dados da ANFAVEA (Associação Nacional dos Fabricantes de Veículos Automotores) acerca de automóveis produzidos entre 1957 e 2016, onde dividiu-se 80% do conjunto de dados destinado ao conjunto de treinamento e 20% para o conjunto de validação. Variou-se entre 2 e 24 os neurônios da camada de entrada e entre 5 e 20 os neurônios da camada oculta. A rede ainda encontra dificuldade em seu processo de aprendizagem visto que são muitas as variáveis complexas que impactam seu desempenho, porém a MLP se mostrou uma excelente ferramenta no auxílio à tomada de decisão em relação à previsão de séries temporais e justificou seu uso, uma vez que a taxa de acerto em relação aos erros MAPE (Média Percentual Absoluta do Erro) e MSE (Erro Quadrático Médio) foi maior que 92%.

Palavras-chave: Multi-Layer Perceptron. Séries Temporais. Previsão.

ABSTRACT

ALMEIDA, Lucas Gonçalves Martins de. **Multi-Layer Perceptron for the forecast for the demand of the automobile industry in Brazil**. 2018. 59 f. Work of Conclusion Course (Graduation in Production Engineering) - Federal Technology University of Paraná. Ponta Grossa, 2018.

It is known that for companies, it is essential to try to predict what will happen in the near future when it comes to the market, so that they can prepare themselves and make the right decisions in a timely manner. The forecasts can be of the most varied types such as demand, sale, purchase, production, market variation, inflation variation, stock, among others. It is very important that companies can obtain this information with great accuracy, that is, with the least possible deviation from reality, for success in a market as competitive as the current one. Many companies use the most varied forms to obtain these types of variables, and as technology advances at an accelerated pace, more and more Artificial Intelligence (AIs) have been used. Artificial Neural Networks (ANNs) are an AI in which its use has been growing consistently, where it is inspired by the functioning of the human brain. ANNs work in a similar way, where they try to recognize patterns and regularities, and are able to learn through training, accumulate knowledge (experience) and make generalizations. The purpose of this paper is to verify the efficiency of the RNA of Multi-Layer Perceptron architecture (MLP) in the forecast of motor vehicle demand in Brazil. Data from ANFAVEA (National Association of Motor Vehicle Manufacturers) were used for automobiles produced between 1957 and 2016, where 80% of the data set for the training set and 20% for the validation set. The input layer neurons varied between 2 and 24 and between 5 and 20 neurons of the hidden layer AI still finds difficulty in its learning process since there are many complex variables that impact your performance, but MLP has proved to be an excellent tool to aid decision making in relation to time series prediction and justified its use once that the hit rate for MAPE (Mean Absolute Percentage Error) and MSE (Mean Square Error) errors was greater than 92%.

Keywords: Multi-Layer Perceptron. Time Series. Forecast.

LISTA DE FIGURAS

Figura 1 – Modelo de neurônio artificial.....	29
Figura 2 – Arquitetura de uma MLP.....	32
Figura 3 – Erros de treinamento e de validação por épocas.....	37
Figura 4 – Fases da pesquisa.....	39
Figura 5 – Série Temporal.....	40
Figura 6 – Topologia da MLP.....	42
Figura 7 – Fluxograma do processo de treinamento da MLP.....	43
Figura 8 – Gráfico do erro pelo número de épocas no treinamento da MLP.....	47
Figura 9 – Gráfico Amostras pelo Tempo.....	50
Figura 10 – Taxa de acerto por número de neurônios na camada de entrada.....	52

LISTA DE TABELAS

Tabela 1 – Comparação de Veículos Licenciados e Ranking Mundial ao longo dos anos.....	20
Tabela 2 – Principais características da MLP.....	45
Tabela 3 – Comparação de erros com 2 neurônios na camada de entrada	49
Tabela 4 – Comparação de erros com 24 neurônios na camada de entrada	49
Tabela 5 – Taxa de acerto por número de neurônios na camada de entrada	51

LISTA DE SIGLAS, ABREVIações E ACRÔNIMOS

ANFAVEA – Associação Nacional dos Fabricantes de Veículos Automotores

GM – General Motors

IA – Inteligência Artificial

IBGE – Instituto Brasileiro de Geografia e Estatística

MAPE – Mean Absolute Percentage Error (Média Percentual Absoluta do Erro)

MATLAB® – marca registrada da empresa The Mathworks, Inc

MLP – Multi-Layer Perceptron (Perceptron de Múltiplas Camadas)

MSE – Mean Square Error (Erro Quadrático Médio)

RNA – Redes Neurais Artificiais

SUMÁRIO

1 INTRODUÇÃO	10
1.1 PROBLEMA	11
1.2 JUSTIFICATIVA	11
1.3 OBJETIVO GERAL	12
1.4 OBJETIVOS ESPECÍFICOS	12
1.5 DELIMITAÇÃO DO TEMA.....	12
2 REFERENCIAL TEÓRICO	14
2.1 A INDÚSTRIA AUTOMOBILÍSTICA NO BRASIL.....	14
2.1.1 Histórico da Indústria Automobilística no Brasil.....	14
2.1.2 Cenário Atual.....	19
2.1.3 Perspectivas Futuras.....	21
2.2 SÉRIES TEMPORAIS	23
2.2.1 Previsão de Séries Temporais	23
2.2.2 Tipos de Métodos de Previsão de Séries Temporais	27
2.3. REDES NEURAS ARTIFICIAIS	29
2.3.1 Conceito das Redes Neurais Artificiais	29
2.3.2 Perceptron de Múltiplas Camadas (MLP).....	31
3 METODOLOGIA	38
3.1 CLASSIFICAÇÃO DA PESQUISA	38
3.2 FASES REALIZADAS NA PESQUISA	39
3.2.1 Base Escolhida e Preparação dos Dados	40
3.2.2 Montagem da Etapa de Treinamento	40
3.2.3 Teste de Rede.....	41
3.2.4 Análise dos Resultados.....	41
3.2.5 Discussão e Considerações dos Resultados	41
4 DESENVOLVIMENTO DA REDE NEURAL ARTIFICIAL MLP	42
5 RESULTADOS E DISCUSSÕES	47
6 CONSIDERAÇÕES FINAIS	53
REFERÊNCIAS	54

1 INTRODUÇÃO

As inovações tecnológicas estão gradativamente mais presentes no cotidiano das pessoas e em constante e rápido desenvolvimento. Não só mais presentes em seu cotidiano, mas também progressivamente influenciando nas tomadas de decisões das pessoas. Desde decisões mais simples, até grandes e importantes decisões nas empresas.

Dentro de uma organização, uma série de decisões são tomadas diariamente, que influenciam no todo da cadeia de produção. Por exemplo, o quanto deve ser produzido, quanto de estoque, quanto comprar de matéria-prima, equipamentos, organização estrutural e operacional da empresa, entre outras. Consequências financeiras estão direta ou indiretamente ligadas a essas decisões e não podem ser ignoradas (CHOI; KRAUSE, 2006).

As tecnologias sempre estiveram presentes no âmbito industrial, principalmente no automobilístico, auxiliando em suma na produção de chão de fábrica, como o uso da robótica na montagem e pintura de chassis por exemplo. Porém a aplicabilidade de tecnologias nas tomadas de decisões importantes das empresas ainda pode ser considerada recente, uma vez que muitas delas começaram proximamente a investir e se preocupar mais com a chamada Tecnologia da Informação (TI) e Sistema de Gestão Integrado (SGI). Segundo Keen (1996), a TI é uma forma de capacitação onde tem o poder de eliminar barreiras entre coordenação, serviço e colaboração, na qual se iniciou na década de 1990 a era da integração e reestruturação do negócio.

Um dos mais importantes fatores dentre as vantagens competitivas e nas tomadas de decisões das empresas é ter certa percepção do quanto terá de demanda em curto, médio e longo prazo. Isso é necessário para a empresa poder realizar sua estratégia de compra, de produção, de venda, *marketing*, novas linhas de negócio, fluxo de estoque, entre outras importantes decisões estratégicas.

A inteligência artificial se mostra uma ferramenta muito valiosa para esse fim. Redes Neurais Artificiais (RNAs) podem ser aplicadas em problemas de previsão pela “estimativa de situações futuras com base nos estados atuais e anteriores do sistema a ser modelado” (BRAGA et al, 2007).

Essa pesquisa visa aplicar a MLP na previsão de demanda do setor automobilístico brasileiro, e assim, auxiliar na projeção de um cenário para analisar

sua eficiência neste propósito, a partir de dados coletados da Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA).

1.1 PROBLEMA

Até que ponto a Rede Neural Artificial com arquitetura do tipo de MLP pode ser utilizadas como ferramenta para análises de previsão de séries temporais da demanda de veículos automotores no Brasil?

1.2 JUSTIFICATIVA

A indústria automobilística brasileira é um dos maiores setores do país, sendo, segundo o Instituto Brasileiro de Geografia e Estatística (IBGE), responsável por cerca de 23% do PIB industrial e 5% do PIB total (2014). Visto isso, tem grande influência nos números da economia.

Para Whight e Upadhyaya (1996), os pesquisadores que se especializam no processo de previsão de demanda têm um crescente interesse pela interação de métodos estatísticos mais eficazes. Por poderem extrair informações de dados coletados históricos, porém, limitam-se a essas informações.

De acordo com Lindberg e Zackrisson (1991), o grande problema em relação ao uso de previsões para tomada de decisões está na escolha do método que irá gerar a previsão; e para Armstrong (2001), pesquisas que contribuem com o refino e desenvolvimento de seleção de métodos para previsão são sempre úteis.

O fator de importância do setor, combinado com a importância da previsão de demanda para as empresas, faz com que a MLP apresente interessante recurso de ferramenta para uma melhor precisão e concisão nos resultados.

A MLP tem a capacidade de incorporar várias entradas simultaneamente e distribuí-las de forma organizada onde as informações são repassadas por todas as unidades (neurônios) do processamento, diferentemente do sistema de instruções sequenciais, em que a informação fica retida na memória em determinado endereço (PASQUOTO, 2010).

Por conta desses fatores de diferenciação entre MLP e demais modelos de previsão de demanda, se dá a justificativa para o desenvolvimento de pesquisas relacionadas à utilização dessa tecnologia. Acredita-se que com a habilidade

necessária para utilização e posterior análises de resultados, o gestor possa tomar a correta decisão a cerca do gerenciamento de compras e vendas, fluxo de estoque e de caixa. Com a obtenção de êxito em sua tomada de decisão, possivelmente o gestor possa trazer ganhos financeiros para a empresa, seja em otimização de recursos, redução de custos ou até aumento da receita.

1.3 OBJETIVO GERAL

Avaliar o desempenho da Rede Neural Artificial MLP na previsão da demanda de veículos automotores no Brasil.

1.4 OBJETIVOS ESPECÍFICOS

- Analisar dados históricos de demanda de veículos automotores no Brasil;
- Realizar revisão bibliográfica acerca do tema
- Escolher topologia, preparar, treinar e validar a MLP;
- Analisar por meio de gráficos o comportamento dos dados de saída obtidos e a taxa de acerto em relação ao MSE e MAPE;

1.5 DELIMITAÇÃO DO TEMA

A área na qual essa pesquisa pode ser classificada se chama “Pesquisa Operacional”, abordando como temática assuntos ligados à tecnologia computacional.

No quesito viabilidade, essa pesquisa se mostra viável uma vez que a utilização de *softwares* para preparação, treinamento, e execução da MLP foi realizado no Centro de Estudos em Instrumentação nas Áreas de Engenharia Biomédica e Esportiva da Universidade Tecnológica Federal do Paraná, campus de Ponta Grossa.

O intuito é verificar através dos dados históricos o comportamento das Redes Neurais por meio de gráficos, análise do MAPE – *Mean Absolute Percentage Error* (Média Percentual Absoluta do Erro), MSE – *Mean Square Error* (Erro Quadrático Médio), do erro absoluto, e por fim, verificar a eficácia da RNA do tipo

MLP com topologia *feedforward* para a previsão de uma série temporal, no caso, previsão de demanda de automóveis no Brasil.

2 REFERENCIAL TEÓRICO

Essa seção está dividida em três grandes tópicos: A indústria automobilística no Brasil, séries temporais e RNA. Dentro de cada tópico contém as definições e conceitos necessários para o entendimento desta pesquisa, a qual tem como enfoque o uso da Rede Neural MLP para previsão de séries temporais.

2.1 A INDÚSTRIA AUTOMOBILÍSTICA NO BRASIL

2.1.1 Histórico da Indústria Automobilística no Brasil

A indústria automobilística no Brasil é uma das mais importantes dentro dos setores industriais. Importância essa devido seu tamanho, sua alta capacidade na geração de empregos, inovação tecnológica de processos, maquinários, produtos, bem como investimentos em Pesquisa e Desenvolvimento e também pela questão econômica, cultural e social (ANFAVEA, 2014).

A história da indústria automobilística no Brasil começa quando os maiores representantes da indústria de automóveis chegaram ao país; a Ford, no ano de 1919, e a General Motors em 1925; porém ambas desembarcaram como montadoras. No início, as peças vinham de fora e o que se fazia era apenas montá-las, nada era produzido (Correia, 2008).

Dois marcos históricos influenciaram o começo da produção de automóveis no país. Um deles foi após a Revolução de 1930, onde Getúlio Vargas implantou uma nova mentalidade no governo, que começou a gerar resultados em 1956 (PIMENTA, 2002). Outro marco importante foi o fim da Segunda Guerra Mundial em 1945, onde o Brasil – assim como boa parte do mundo – contava com uma frota envelhecida de carros e caminhões dos anos 30, uma vez que os esforços de fabricantes e uso de matéria-prima estava voltado a fazer veículos militares. Passada a guerra, juntamente com uma alta e desequilibrada inflação, aumentou-se o interesse por produtos importados como carros e autopeças. O governo resolveu agir e tomou medidas para restringir as importações acentuadas de veículos automotores e autopeças.

Dois fatores foram importantíssimos para a estruturação do parque industrial brasileiro, formado não só por fábricas, mas como serviços de infraestrutura e rede

de fornecedores. Um deles foi a inauguração em 1946 da Companhia Siderúrgica Nacional em Volta Redonda (RJ) e também a autonomia nacional na produção de petróleo e derivados pelo crescimento exponencial da Petrobrás, fundada em 1953.

A situação dos grandes fabricantes estrangeiros era de expansionismo para o exterior, uma vez que seus mercados internos estavam saturados; entretanto, os mesmos julgavam inviável produzir carros no Brasil por conta de falta de mão-de-obra especializada, matéria-prima e infraestrutura.

Em 1953, o governo fez uma manobra ousada e importante para a progressão da indústria automobilística brasileira. Primeiramente limitou a importação de peças de reposição já produzidas no país, como também a proibição de importar carros inteiros. Sendo assim, algumas fábricas acabaram se tornando nacionais, como a Volkswagen e Mercedes-Benz por exemplo.

Em maio de 1956 é fundada a Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA) e em julho, dando continuidade as ideias de Getúlio Vargas, o então presidente Juscelino Kubitschek criou o GEIA (Grupo Executivo da Indústria Automobilística), órgão de regulamentação e supervisão de normas da indústria automobilística brasileira. Com o estabelecimento da promessa “50 anos em 5”, a fabricação local era um dos pilares do governo de Juscelino Kubitschek. Esse ano em especial marca o início da fabricação de motores da GM (General Motors) em São José dos Campos (SP) (o que viria a se tornar fábrica de veículos três anos mais tarde), ao mesmo tempo que a Mercedes-Benz inaugurava sua fábrica em São Bernardo do Campo (SP), assim como a Volkswagen também se transferia para a mesma cidade.

Até 1960, o plano sólido traçado pela GEIA previa que 90% dos componentes dos caminhões deveriam ser nacionais e 95% para automóveis de passeio, objetivos esses que foram inclusive ultrapassados, consolidando assim o início efetivo da indústria automobilística brasileira, a qual cresceria exponencialmente e viria a se tornar uma das maiores do mundo. No mesmo ano, iniciou-se o “Salão do Automóvel” no Parque do Ibirapuera em São Paulo (ANFAVEA, 2014).

Em 1969 ocorreu a primeira exportação brasileira de veículos leves para o Chile. Oito anos antes, houve a primeira exportação de veículos pesados para Argentina e Venezuela. Com isso o Brasil já demonstrava ser a grande potência da indústria automobilística da América Latina.

O período entre 1970 e 1990 foi marcado por uma intensa corrida das grandes fabricantes de expandirem suas fábricas, aumentarem suas capacidades, entrarem em novos ramos de negócios (como a Volkswagen Caminhões em 1980), e a chegada de novos gigantes como a Volvo, iniciando a produção de caminhões nesse mesmo ano. No final da década de 80, o Brasil apresentava atraso tecnológico em comparação aos países do G7 e a produção de veículos concentrava-se entre poucos fabricantes: Ford, Volkswagen, Fiat, GM, Toyota, Mercedes-Benz, Scania, Agrale e Volvo. Por conta disso, acabou-se criando certas barreiras nos investimentos das montadoras do setor. A nível internacional, as fabricantes japonesas saíam na frente com suas inovações tecnológicas e o conceito de produção enxuta, o que desviava atenção e investimento para as fábricas nos países avançados, em detrimento ao aprimoramento das unidades estabelecidas em economias menos desenvolvidas (LATINI, 2007).

É importante ressaltar o cenário político e econômico na qual passava o Brasil por volta de 1990. Crise da dívida externa, hiperinflação persistente, juros elevados, estagnação econômica e uma elevada tarifa de importação de veículos (que chegava a 85%) eram fatores que contribuíam para a não realização de investimentos no setor (PIANI; MIRANDA, 2006). Conforme apontado por Kupfer (1998): “as condições internas aos investimentos eram adversas, mas a proteção à indústria impedia a ameaça à sobrevivência das empresas, desestimulando a realização de gastos em elevação da produção e atualização tecnológica”.

No início da década de 90, década chave para o crescimento da indústria automobilística no Brasil, a indústria começa a passar por intensas e profundas mudanças para tentar se adequar ao cenário internacional, tendo que rever sua estrutura e comportamento. O então presidente Fernando Collor, com a intenção de aquecer a economia brasileira e modernizar o chamado “pátio industrial”, promoveu a ampla concorrência aberta, com a abertura da economia brasileira. Essa ação teve impacto direto e profundo no setor automobilístico. Entretanto, não houve preparação estratégica por parte das empresas nacionais, e nem mecanismos de defesa contra as importações. Como consequência, as empresas nacionais tiveram que remodelar completamente suas estratégias de forma a se adaptar aos novos cenários criados pela indústria automobilística no mundo. Ao tentar se readaptar, o pátio industrial brasileiro, em relação ao setor automobilístico, se mostrou mais uma vez com defasagem tecnológica e falta de condição estrutural, consequência

provocada pela falta de investimento no período em que as importações estavam proibidas, na qual foi incentivado a produção de modelos locais, e também por conta da barreira de novas tecnologias entrantes.

Segundo Botelho (2002), antes da abertura de mercado brasileiro o cenário das empresas era de baixa produtividade e qualidade de produtos, baixo nível de automação na linha produtiva, conflitos com trabalhadores e padrão de estratégia de trabalho no taylorismo/fordismo; além de não ter grande preocupação com a qualidade de seus produtos e nem com preços.

Do ano de 1990 até o começo do Plano Real, em 1994, foi priorizada a estabilidade ao crescimento. Para não ocasionar a perda de mercado, optou-se pela criação de “carros populares”, também chamados de “carros mil”, com uma redução significativa dos preços dos veículos devido a incentivos fiscais. Esses automóveis conseguiam atingir o público que não tinha acesso às novas opções, e assim sustentando parte das empresas locais, com as quais conseguiam margem necessária para manterem preços competitivos em outros mercados.

Entre os anos de 1995 a 2001, com a intenção de incentivar investimentos e equilibrar a balança comercial do setor automobilístico, ocorreu a fixação de algumas regras de negociações entre governo e fabricantes. Um exemplo disso foi o aumento expressivo da tarifa de importação de veículos que passou de 27,71% em 1994 para 217,53% em 95 e 96 (ANFAVEA, 2009). Os investimentos tinham como destino a estrutura tecnológica de processo e maquinário, com base na microeletrônica.

Em relação aos fornecedores, segundo Neto e Pires (2007), existe um elevado grau de *outsourcing* (terceirização para produção de peças ou outros componentes) se tratando de consórcios modulares, assim como gestão do conhecimento e intercâmbio de informação, coprodução de itens, contratos de longo prazo, que acentuam parcerias e aperfeiçoam as empresas ligadas à cadeia de suprimentos.

Ao mesmo tempo em que ocorria a reestruturação da cadeia produtiva do setor automotivo brasileiro, ocorria o processo de descentralização da produção. Este processo tendia a se deslocar para diferentes regiões do Brasil, se afastando dos grandes centros, buscando melhores incentivos fiscais. Em conjunto com essa batalha fiscal entre estados, as montadoras preferiram se afastar das zonas

metropolitanas também por conta da diferença salarial, destacando-se na produção de veículos, na década de 1990, os estados do Paraná e Rio Grande do Sul.

Para Almeida et. al. (2006) a partir de 1995 até 1999 houve a retomada dos investimentos e conseqüentemente o fomento do mercado, a dinamização da demanda as quais estavam ligadas as políticas setoriais, como a do regime automotivo.

Segundo Silva (2002), a indústria automobilística do país passou por grande reformulação de estratégia – muito devido à acirrada concorrência externa, as quais proporcionavam melhores produtos a preços competitivos – e teve que se reinventar em alta velocidade para reduzir a defasagem tecnológica e poder se equiparar em questão de mercado e negócios com as empresas que aportavam no país. Uma das mudanças de visão foi a priorização da relação com seu consumidor, até então taxado como “última das preocupações”. Aliado a isso, novos métodos de gestão, aprimoramento da automatização de processos, investimento em mão-de-obra qualificada, novas parcerias, estrutura para atender mercado interno e externo e principalmente a consolidação no Mercosul, formado em 1991.

Paralelamente ao fomento e crescente mercado automobilístico brasileiro, algumas crises econômicas internacionais acabaram afetando a produção brasileira em determinado período. Pode-se citar algumas delas como a Crise Asiática (1997-98), Moratória Russa (1998-99) e a Crise Argentina (1998-2002), juntamente com a desvalorização do Real em meados de 1999. Observa-se então uma queda na produção a partir de 1998 até 2003, decorrente das crises citadas e maturação de investimentos de novos fabricantes no mercado brasileiro, como Honda, Mitsubishi, Toyota, Renault, Iveco, Peugeot-Citroen e Nissan.

No ano de 2004, abre-se então uma nova fase na história da indústria automobilística brasileira, e tem como característica o aquecimento do mercado externo e doméstico. Pode-se atrelar esse crescimento à plataforma do governo Lula que teve início em 2002 e foi até 2010 onde teve êxito o crescimento sustentado da economia e conseqüentemente uma crescente produção e demanda de veículos no Brasil. Juntamente com isso, a queda na taxa de juros Selic e mudanças na concessão de crédito, as quais impulsionaram o mercado interno. Dados coletados pelo BNDES (2015) mostram que além de investimentos realizados em modernização de processos produtivos e desenvolvimento, as montadoras têm também aumentado sua capacidade produtiva. Para um quadro comparativo, entre

os anos de 1999 e 2009, as vendas cresceram em 40%, saltando de 1,256 milhões para 3,141 milhões de veículos (ANFAVEA, 2010).

Segundo Possas (1985), o setor automobilístico se mostra como um oligopólio concentrado e diferenciado, por apenas alguns poucos grupos empresariais representarem o mesmo, com alto volume de capital, e um grande leque de opções de produtos diferenciados.

Não só concentrado, o setor automobilístico brasileiro não é nada “convidativo” a novos entrantes, uma vez que possui densas barreiras como enorme capital inicial de investimento, alta tecnologia e inovações, dependendo de alto investimento em pesquisa e desenvolvimento, assim como publicidade e propaganda. Atrelado a isso está o fato de cada vez mais ser necessário a mão-de-obra mais especializada.

Sabe-se que para o consumidor, o automóvel tem uma importância que vai além de um meio de transporte. Culturalmente, ter o próprio carro é questão de status. Muitos sonham em ter o primeiro carro e colocam isso como meta e conquista pessoal. Mais do que isso, a própria estrutura do país leva a esse tipo de mentalidade. Historicamente predominou-se muito mais os modais do tipo rodoviário de transporte, com concessões para as empreiteiras que fazem estradas e rodovias, em comparação a outros tipos de modais, como aquaviário ou ferroviário por exemplo.

2.1.2 Cenário Atual

Alguns fatores precisam ser levados em conta quando se fala sobre produção e demanda de automóveis no Brasil. Um dos fatores mais fortes que causa maiores impactos nesses números é como está a situação econômica do país, e é justamente neste fator que o setor automobilístico brasileiro têm mais sofrido nos últimos anos.

A Tabela 1 demonstra as colocações do Brasil no ranking dos maiores vendedores mundiais de veículos ao longo dos anos segundo a Federação Nacional da Distribuição de Veículos Automotores (FENABRAVE), juntamente com a quantidade de automóveis licenciados em um período de 10 anos.

Tabela 1 – Comparação de Veículos Licenciados e Ranking Mundial ao longo dos anos

Ano	Veículos Licenciados	Ranking Mundial
2006	1.883.773	9
2007	2.338.621	9
2008	2.670.852	6
2009	3.011.285	5
2010	3.328.254	4
2011	3.425.495	4
2012	3.634.639	4
2013	3.575.947	4
2014	3.328.958	4
2015	2.476.981	4
2016	1.986.436	7

Fonte: Federação Nacional da Distribuição de Veículos Automotores (FENABRAVE)

Segundo o presidente mundial da OICA (Organização Internacional de Construtores de Automóveis) e ex-ministro de Transporte da Alemanha, Matthias Wissmann, em 2016 a produção brasileira encolheu 11%. Ainda segundo a OICA, em relação ao mercado mundial, o ano foi de crescimento de 4,5%, com o Brasil indo totalmente na direção contrária (ANFAVEA, 2016).

Todo esse cenário tem uma explicação. Uma das maiores crises políticas na história do país, que acarretaram em inúmeros escândalos de desvios milionários de dinheiro público e falta de credibilidade nas instituições brasileiras. Com todo esse cenário adverso e complexo, o Brasil foi rebaixado na nota das principais agências de classificação de risco, como a Fitch por exemplo, o que significa que o país perdia a garantia de “bom pagador” (FITCH RATINGS, 2017). Com essa desconfiança em alta, investimentos no setor automobilístico são deixados de serem feitos, o que reduz o incentivo à pesquisa e desenvolvimento, às novas tecnologias e inovações.

Os dados revelados acima se referem ao setor em si, à política e à economia. Porém os maiores afetados, e conseqüentemente os que mais respondem sensitivamente as mudanças, são os consumidores, ou seja, o trabalhador brasileiro.

Segundo dados da ANFAVEA, a indústria automobilística brasileira gera em torno de 1,5 milhões de empregos todo ano, diretos e indiretos. Entretanto, com a crise generalizada, o medo e desconfiança dos consumidores aumentaram, e como consequência, seus hábitos acabaram mudando também.

Primeiramente o fator de que a taxa de desemprego no Brasil tem aumentado exponencialmente nos últimos anos. Segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2017), o desempregou atinge 13,5

milhões de brasileiros, maior taxa desde 2012. Com esses dados, o brasileiro acaba deixando de entrar em um consórcio e adquirindo um novo veículo, pois no momento tem outros gastos e certa insegurança de adquirir uma nova e possivelmente longa dívida.

Para se ter uma ideia da gravidade do estado atual da economia brasileira, é necessário olhar o desempenho do Produto Interno Bruto. O PIB brasileiro recuou por dois anos seguidos (2015 e 2016), só verificada uma baixa seguida assim nos anos de 1930 e 1931. Caracteriza-se assim a pior recessão da história do país (IBGE, 2017)

A indústria automobilística também perdeu espaço na sua fatia do PIB nacional. Em 2010 chegou a ter participação de 6,3% a qual caiu para 4,1% em 2016 (ANFAVEA, 2016). Porém, nem todos os indícios são ruins, pelo menos para o setor automotivo.

A notícia positiva segundo a ANFAVEA é que a produção é embalada pelas exportações a qual deve ultrapassar 3 milhões de veículos em um ou dois anos, e também por parte da recuperação do consumo interno. É imprescindível essa retomada de atividade, para o retorno desse setor importante para a economia brasileira.

2.1.3 Perspectivas Futuras

Intitulado pelo Ministério da Indústria, Comércio Exterior e Serviços de “Rota 2030”, tem o intuito de criar um grupo de trabalho que planeje a política industrial para além dos ciclos de quatro em quatro anos, que são os ciclos políticos normais. “A proposta é que esse movimento de inserção global seja progressivo, permitindo que, ao final da vigência do programa, a indústria nacional integre a produção mundial de veículos automotores”, explica o ministro da pasta, Marcos Jorge de Lima (GOVERNO DO BRASIL, 2018).

Como o quadro interno é de baixa demanda, o setor automotivo busca ampliar suas exportações, enquanto a política e sua respectiva estratégia a longo prazo começa a ser debatida. No planejamento para 2030, o ministério acredita que a indústria nacional deve chegar com “tecnologia equivalente a de mercados avançados, integração ativa na cadeia global de suprimentos, competitividade na produção dos principais sistemas automotivos e capacidade de desenvolvimento de

projetos globais” (GOVERNO DO BRASIL, 2018). Em comunicado, a pasta afirmou que “para tornar o Brasil um polo global de desenvolvimento e produção de veículos, o novo ciclo da política automotiva terá como guia as novas tendências de mobilidade” (GOVERNO DO BRASIL, 2018).

É sabido que uma nova revolução na indústria automobilística está chegando, e como todo momento de *trade-off*, as empresas precisam decidir entre o que fazem muito bem e com segurança versus o novo e um tanto desconhecido caminho pela frente. Maior exemplo das mudanças que vem por aí é o fato da empresa Tesla (fabricantes de carros elétricos), ter superado Ford e a GM e se tornado a montadora com maior valor de mercado nos EUA (FENABRAVE, 2017)

Não são apenas as grandes empresas como BMW, Toyota, Ford e GM que estão de olho nas mudanças que irão ocorrer daqui para frente. Petrolíferas e empresas do ramo também estão muito atentas às novas tendências. Isso porque países como França, Reino Unido, Alemanha, Japão, entre outros, já anunciaram que encerrarão a produção de carros movidos à combustão (gasolina e diesel) já nos próximos anos. Mais que isso, até 2040 o Reino Unido vai banir esses tipos de carros (ABERJE, 2017). O Brasil, enquanto isso, segue em outra direção.

Atualmente no Brasil a frota de veículos elétricos e híbridos é 20 vezes menor do que a média mundial. Para cada 10 mil veículos com motor a combustão no Brasil, roda um carro elétrico, bem diferente da proporção de 500 veículos com motor a gasolina ou diesel para cada um elétrico no resto do mundo. “No Brasil, estamos, no mínimo, cinco anos atrasados em relação ao mundo”, afirma Ricardo Takahira, diretor do núcleo de pesquisas da Associação Brasileira do Veículo Elétrico (ABVE).

Takahira explica que um modelo aqui precisa vender 50 mil unidades por ano para ser economicamente viável para as montadoras. A entrada de carros elétricos no país se iniciou em 2006 e até então foram comercializados pouco mais de 5000 com motor elétrico ou híbrido (ANFAVEA, 2016).

O principal fator de não incentivo em relação aos carros elétricos no Brasil é o fato de o país não ter a estrutura necessária para recebê-los, o que entra outra vez na questão de defasagem tecnológica.

Algumas barreiras e desafios terão de ser contornados caso o Brasil venha a se tornar também um país que seguirá a tendência mundial. Garantia da bateria, tempo de recarga, e principalmente o preço são alguns deles. Para carros elétricos,

existe a isenção do Imposto de Importação, o que ajuda o consumidor que queira adquirir. Entretanto, os preços ainda são cerca de 20% maiores comparados aos carros já existentes.

Visto todo esse cenário de perspectivas futuras, a previsão de demanda e de produção se torna ferramenta imprescindível para as empresas, tanto em termos de entendimento e análise do mercado, quanto em termos de livre concorrência, e *marketshare*. Quanto mais fiel os dados de previsão forem próximos à realidade, mais preparada estará a empresa para fazer seu planejamento estratégico e tomada de decisões.

2.2 SÉRIES TEMPORAIS

2.2.1 Previsão de Séries Temporais

Série temporal é um conjunto de dados os quais são ordenados em determinado parâmetro de tempo equidistante, como dias, meses ou anos, por exemplo (Souza; Camargo, 2004).

As empresas que querem sobreviver e verem seus negócios prosperarem precisam estar preparadas para a rapidez e o dinamismo das mudanças de mercado e de cenários as quais as mesmas terão de enfrentar.

Estar preparado para o mundo corporativo exige das empresas alguns olhares e visões em diferentes tempos. Necessita-se olhar ao passado e fazer análises dos dados históricos apresentados, olhar cautelosamente para o presente e como está a situação da empresa inserida no mercado atual, e ter uma visão de futuro, para curto, médio e longo prazo, tentando assim encontrar as melhores estratégias para a empresa, saber quais as melhores e possíveis tomadas de decisões a serem feitas (KAZMIER, 1975).

As visões de futuro são as mais complexas primeiramente por não se saber com certeza o que virá pela frente, qual reação o mercado terá com novos entrantes, produtos, preços, ou até fatores externos e não controláveis como uma crise financeira do governo, escândalos e desastres naturais, fatores que podem influenciar de forma positiva ou negativa na compra, venda, demanda, *stakeholders*, consumidores e as empresas. Segundo fator da complexidade da visão futura é a mudança de hábitos e de percepção dos consumidores, como dito anteriormente,

visto que não estão mais interessados apenas em qualidade, preço, conforto e *design*, porém cada vez mais preocupados e inclinados a comprar produtos de empresas que se preocupem com o meio-ambiente, sustentabilidade, com bem-estar de seus funcionários e a sociedade em si. Último e não menos importante fator de complexidade da visão futura que as empresas precisam ter para estarem preparadas para lidar com o mercado é o acompanhamento de perto e sistêmico das inovações tecnológicas e de serviços que entram no mercado e cada vez mais influenciam nos números em vários setores, inclusive no automobilístico.

O exemplo recente mais clássico de empresa que era líder absoluta de mercado e que não teve a preocupação de visão futura e inovação tecnológica é a Blockbuster, a qual em 2014 decretou falência e encerramento das atividades, devido principalmente aos novos entrantes que ofereciam o mesmo serviço (aluguel de filmes e séries) de forma diferenciada, como a Netflix, por exemplo, e a falta de visão da empresa das mudanças de tendência do mercado. Caso semelhante já havia acontecido com a Kodak em relação às câmeras digitais, entre outros exemplos.

Como citado anteriormente, em relação ao setor automobilístico, as principais mudanças e inovações são acerca dos carros elétricos em contrapartida aos de combustão, e também as *startups* que pregam a inovação no meio de utilizar seu automóvel.

As previsões de séries temporais tem sua importância, visto todos os fatores citados acima, no sentido de as empresas conseguirem de certo modo preverem – através de cálculos matemáticos probabilísticos e estatísticos, analisando histórico de dados – qual será sua demanda, para assim, saber qual deverá ser sua produção, qual estratégia de decisão tomar, quais deverão ser os gastos e a receita, entre outros indicadores de desempenho. Quanto mais perto as previsões chegarem da realidade, melhor para a empresa, pois evita muito estoque parado, reduz custos, produtos à pronta entrega, entre outros fatores.

A previsão de demanda ajuda no dimensionamento e planejamento de estoques, evitando assim perda de vendas (caso de o cliente não encontrar o produto desejado), grandes excessos e perdas pelo vencimento de produtos (RODRIGUES; PIZZOLATO, 2003). No setor automobilístico, o excesso de veículos parados pode gerar depreciação (uma vez que os veículos ficam a céu aberto expostos a sol, chuva, umidade) e até no caso de lançamento de uma nova versão,

ou ainda veículos saindo de linha, as concessionárias nesse caso geralmente são obrigadas a fazerem promoções, podendo até não cobrir os custos de seu produto.

Segundo Fabio Favaretto (2012), o planejamento de estoques se relaciona no atendimento de prazos de entrega e os custos de produção das empresas, as quais o aglomerado de informações para tomada de decisão dentro do planejamento são: tempo de reposição, níveis de estoque e demanda. Para o planejamento não apresentar falhas, essas variáveis não podem ser incertas.

Para Juliano Zaffalon Gerber (2013) é importante o envolvimento dos altos gestores para a utilização de métodos de previsão de demanda, necessitando entender como as previsões vem sendo realizadas e o quão diferente da realidade estava. Não existindo um método estruturado aplicado na empresa, ainda assim, os gestores devem utilizar de suposições intuitivas para o planejamento das atividades na organização.

Pellegrini e Fogliatto (2001) demonstram como importância das previsões de demanda dentro de uma organização, o gerenciamento de estoques através do *lead time* do ideal de entrega e a taxa de utilização do produto perante o planejamento da capacidade, obtendo assim qual a real necessidade de itens em estoque intermediários.

Existe uma certa divergência de opiniões entre especialistas do setor automotivo e especialistas em análise de previsão, em relação aos métodos de previsão. Os primeiros se baseiam grande parte em análise qualitativa, onde se leva em consideração a experiência de vivências pessoais e profissionais das pessoas envolvidas. A análise de previsão, no entanto, tem se mostrado ferramenta essencial e eficaz quando feita por métodos quantitativos, de forma os quais são desenvolvidos por modelos matemáticos definidos, capazes de identificar padrões e comportamento das flutuações do mercado perante a oferta de produtos, e realizando previsão da quantidade de vendas no futuro próximo. Kurrle (2004) diz que podem haver combinações entre previsões quantitativas e qualitativas, absorvendo vantagens de cada método, proporcionando assim previsões mais apuradas. Ainda segundo o mesmo autor, a indústria automobilística tem como costume ofertar o que as montadoras são capazes de produzir, e não proporcionar veículos equipados conforme desejo dos clientes. As montadoras costumavam manter amplos estoques de veículos prontos, em sua rede de distribuição, para

poder melhorar o nível de serviço de escolha dos consumidores (HOLWEG; MIEMCZYK, 2003).

Estimam-se que as previsões de demanda quantitativas da quantidade de itens que serão vendidos nos próximos períodos de tempo, baseado pelo comportamento do mercado e de dados históricos, através de modelos matemáticos estruturados encontrados na literatura.

Os comportamentos podem indicar diferentes tipos, como por exemplo: sazonalidade (tendência cíclica com um pico em determinado período do tempo, como a crescente venda de sorvetes no verão, e fraca venda no inverno, por exemplo); periodicidade (tendência da demanda se repetir em certo intervalo de tempo, por exemplo, uma revista que é feita semanalmente, tem função periódica); e uma variação em torno da média (pequenos desvios). Para cada característica que a série de dados apresentar, têm-se um modelo matemático mais adequado usado para fazer a previsão (LIN, 2005).

Segundo Pellegrini e Fogliatto (2001), o sistema de previsão requer conhecimento em 4 áreas básicas:

- a) Identificação e definição dos problemas a serem tratados;
- b) Aplicação de métodos;
- c) Seleção de métodos apropriados a situações específicas e;
- d) Suporte organizacional e adaptação para uso dos métodos requeridos.

Ainda segundo os autores, as etapas necessárias para realiza a análise qualitativa de previsão de demanda envolvem: (i) Definição do problema; (ii) Coleta de informações; (iii) Seleção do pacote computacional; (iv) Análise preliminar; (v) Escolha e validação dos modelos e (vi) Verificação do sistema.

A utilização de métodos de previsão de demanda no setor automotivo é imprescindível, uma vez que o setor trabalha com grande variedade de modelos de veículos e deseja-se saber quantidades para a antecipação de demanda, no planejamento de estoque. É necessário nesse caso a montadora determinar a quantidade de cada modelo de veículo que deverá ser produzido para atender a demanda das concessionárias. Por essa questão de cadeia de suprimentos, é importantíssimo também as próprias concessionárias colaborarem com as montadoras e terem suas previsões de demanda de toda organização, possibilitando previsões regionais e mais pontuais.

Baseia-se a previsão de demanda em dados históricos já estabelecidos, porém no setor estudado na pesquisa, sempre há a opção de casos de lançamentos de novos produtos, os quais não possuem dados históricos para aplicação de métodos estruturados. Segundo Grippa (2005), para esse caso em específico foram desenvolvidos métodos de analogia utilizando dados de produtos com características semelhantes. Ainda segundo o autor, alguns aspectos são relevantes para fazer essa analogia, como nível de inovação, tipo de compradores, fidelidade e condições econômicas.

Deve-se identificar também fatores sazonais que possam influenciar a demanda ao longo do tempo, evitando assim excessos em caso de reposição de estoque em período de baixa demanda e falta de produto em períodos de alta demanda (RODRIGUES E PIZZOLATO, 2003).

Existem alguns tipos de filosofia de produção. As montadoras durante muito tempo utilizaram como filosofia o tipo *push system* (empurrada), determinado conforme o comportamento do mercado, começando a produção antes da demanda pelo produto. Atualmente as empresas têm mudado de filosofia, passando a utilizar o sistema de *pull system* (produção puxada), onde o consumo do cliente determina a quantidade a ser produzida, com a demanda gerada através do desejo do cliente (KURRLE, 2004).

Morettin e Toloi (2004) definem os objetivos das séries temporais como: “identificar a natureza do fenômeno gerador da sequência de observações e fazer previsões de valores futuros da série temporal”.

2.2.2 Tipos de Métodos de Previsão de Séries Temporais

Existem alguns métodos para previsão de séries temporais, como por exemplo:

- Univariados – utilizam-se valores históricos da própria série para estimar valores futuros. Na literatura encontram-se modelos muito utilizados como Box & Jenkins (BOX & JENKINS, 1976); Espaço de Estados (HYNDMAN ET AL, 1988); Modelos de Amortecimento Exponencial (GARDNER, 1985).
- Multivariados – de forma simultânea, realiza-se a previsão de várias séries temporais (HEUTS & BRONCKERS, 1988).

- Casuais – utilizam-se não só valores históricos como também atuais e passados de outras séries, fazendo correlações. (ZANINI, 2000).
- Inteligência Computacional – será o foco deste trabalho de conclusão de curso, onde se adapta a inteligência artificial para prever determinada série temporal, como por exemplo: Redes Neurais, Lógica Fuzzy, Algoritmos Genéricos e Modelos Inteligentes Híbridos (PALIT & POPOVIC, 2005).

A análise de uma série temporal pode ser realizada de duas formas: domínio do tempo e domínio da frequência. No primeiro tipo, tem-se por objetivo determinar em diferentes instantes da série, sua magnitude, e é considerado como o processo se desenvolve ao longo do tempo (SOUZA & CAMARGO, 2004). Já no segundo, consideram-se as frequências em que ocorrem eventos relevantes em certo período de tempo, tendo uma conjunção de funções de diferentes frequências (MORETTIN & TOLOI, 2004).

Focando-se em RNAs, destaca-se o trabalho de Huang (HUANG et al, 2005), onde adotou-se um novo padrão de entrada, o qual tem por objetivo o auxílio no processo de aprendizagem da rede em relação ao comportamento das séries temporais. (HUANG et al, 2005). Comparou-se a exatidão da previsão das RNAs com resultados alcançados por outras conhecidas, a do trabalho de Gutierrez (2008) e a de Mukhopadhyay (2012). A comparação estendeu-se também para dois estimadores conhecidos, Croston (1972) e Syntetos & Boylan (2008).

Utilizou-se dos conhecimentos de Syntetos et al. (2008) para categorizar padrões de demanda baseando-se em seus limites teóricos (0,49 e 1,32, respectivamente), e para a camada de entrada, foram utilizados dois neurônios, e assim que se alcançava o erro mínimo possível, o estágio de treinamento era interrompido. As comparações de desempenho ou medidas de acurácia das séries temporais podem ser feitas de diversas maneiras, uma das mais comuns, utilizada na pesquisa apresentada, é a comparação do MAPE (Média Percentual Absoluta do Erro). Por fim, na comparação entre os métodos padrão (de Croston e Syntetos & Boylan), chegou-se a conclusão que abordar de diferentes formas a aprendizagem não fornece desempenhos diferentes em relação ao erro sistemático relativo. A maior diferença está nas redes treinadas com posterior propagação. O estudo foi realizado em relação a demanda intermitente (LOLLI et al, 2017).

2.3. REDES NEURAIS ARTIFICIAIS

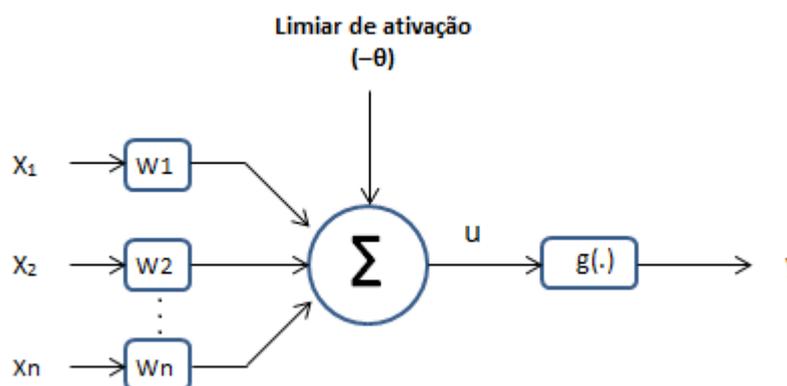
2.3.1 Conceito das Redes Neurais Artificiais

Segundo Silva, Spatti e Flauzino (2010), a Rede Neural Artificial (RNA) se inspira no sistema nervoso dos seres vivos, sendo um modelo computacional, podendo assim através de treinamento e experiência, obter e manter conhecimento. A RNA leva esse nome por sua inspiração com o sistema nervoso biológico, sendo composta por neurônios artificiais que se ligam através de interconexões entre vetores e matrizes, representando assim sinapses artificiais.

RNAs têm como principais características: (i) capacidade de aprendizado através de treinamento; (ii) adaptação por experiência, em que os pesos das sinapses se ajustam conforme a entrada de informações; (iii) habilidade de generalização, pois mesmo que não tenha sido apresentado certa entrada no treinamento, a rede consegue aferir uma solução; (iv) a implementação pode ser realizada em diferentes *hardwares* e *softwares* (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

O modelo básico de um neurônio artificial foi desenvolvido por McCulloch e Pitts (1943), a qual foi baseado na Lei do Tudo ou Nada, modelo esse adotado até os dias atuais, apresentado na Figura 1.

Figura 1 – Modelo de neurônio artificial



Fonte: Adaptado de HAYKIN (2009)

em que:

u representa o potencial de ativação;

w representa o peso sináptico correspondente;

x representa o peso sináptico correspondente;

θ representa o limiar de ativação;

$g(.)$ representa a função de ativação;

y representa a saída da rede neural.

A entrada é representada por x_1, x_2, \dots, x_n , os quais seriam os dendritos celulares, sendo n o número de entradas. Entre a entrada e corpo celular, têm-se as sinapses e seus respectivos pesos, sendo representado por w_1, w_2, \dots, w_n . Faz-se uma multiplicação de cada valor de entrada com seu respectivo peso e após isso, faz-se a somatória de todas essas multiplicações. Este valor somado é subtraído de um limiar de ativação (θ), o qual gera um valor de disparo, em relação à saída do neurônio, chamado de potencial de ativação (u), o qual é a entrada da função de ativação. Essa função de ativação ($g(u)$), faz com que se limite a saída do neurônio, para valores que correspondem a respectiva imagem da função. Por último, o sinal de saída (y), o qual é o resultado, ou ainda, o valor final que o neurônio produz, pode ser utilizado como entrada para um próximo neurônio ou o resultado final da RNA. No neurônio biológico, esse último papel é a do axônio, o qual distribui as informações processadas (MCCULLOCH; PITTS, 1943; SILVA; SPATTI; FLAUZINO, 2010).

As duas equações a seguir, de forma simplificada, são as utilizadas no modelo de Mcculloch e Pitts (1943):

$$u = \sum_{j=1}^n W_j X_j - \theta \quad (1)$$

$$y = g(u) \quad (2)$$

As funções de ativação recebem classificações entre parcialmente diferenciáveis e diferenciáveis. As mais utilizadas nas primeiras topologias de redes são as funções parcialmente diferenciáveis, como a *Perceptron* e *Adaline*, e as diferenciáveis aplicam-se em Perceptron de Múltiplas Camadas, Redes de Base Radial (RBF), entre outras (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

O processo de treinamento, e consequentemente, o de aprendizagem neste sistema inteligente é a parte mais importante do todo. O treinamento é o processo onde ocorre a ação de atualizar a informação, ou seja, a resposta ao estímulo

externo apresentado presente nos pesos sinápticos (BASHEER; HAJMEER, 2000). Existem duas formas de se fazer esse processo de treinamento, que é o de forma supervisionada – dados são apresentados com as respectivas saídas – ou não-supervisionada – onde a rede ao encontrar padrões próximos, fornece uma solução pela proximidade entre os dados, os quais as saídas não possuem valores determinados (SILVA; SPATTI; FLAUZINO, 2010).

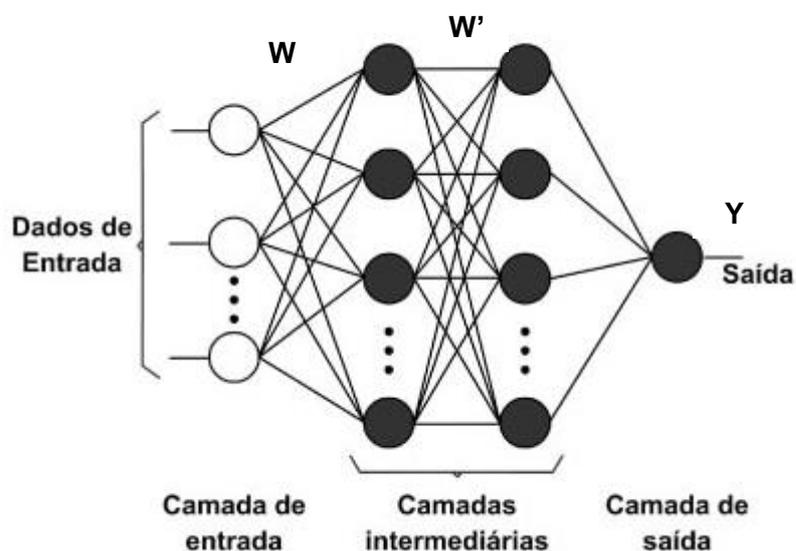
Durante o processo de treinamento, separa-se os conjuntos de dados em dois grupos. Um serve para ajustar os pesos sinápticos e potenciais de ação (conhecido como conjunto de treinamento). No segundo grupo têm-se amostras as quais são colocados os devidos pesos e analisa-se tanto o desempenho da rede, quanto sua capacidade de generalização. Este grupo é conhecido como conjunto de validação (CHOJACZYK et al., 2010).

As funções de ativação podem receber dois tipos de classificação: parcialmente diferenciáveis (função degrau, degrau bipolar e rampa simétrica) ou diferenciáveis (função logística, tangente hiperbólica, linear e gaussiana). As funções parcialmente diferenciáveis são mais utilizadas em redes como *Perceptron* e *Adaline*, ao passo que as diferenciáveis são aplicadas em Redes de Base Radial (RBF), *Perceptron de Múltiplas Camadas (MLP)*, entre outras (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

2.3.2 Perceptron de Múltiplas Camadas (MLP)

Uma MLP é uma variação da *Perceptron* que possui pelo menos uma camada intermediária, conhecida como camada de neurônios oculta. Para que a MLP não seja reduzida a uma *Perceptron*, há a necessidade de se usar uma função que seja diferenciável e com fator de não-linearidade suave. Com isso, utiliza-se como funções de ativação a função logística e tangente hiperbólicas (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010). Por sua flexibilidade de funções, a MLP pode ser encontrada em diversos sistemas, como de processamento de sinais, reconhecimento de padrões e previsão de séries temporais (SILVA; SPATTI; FLAUZINO, 2010). Um modelo de MLP é demonstrado na Figura 2.

Figura 2: Arquitetura de uma MLP



Fonte: Adaptado de HAYKIN, 2009

A informação nessa topologia de rede é passada em um único sentido, arquitetura chamada de *feedforward*. Já seu treinamento é feito por meio do algoritmo de *backpropagation*, de forma supervisionada, em que deseja-se encontrar o mínimo local ou global da função do erro entre entrada e a saída (GARDNER, 1985). Este algoritmo utiliza a técnica do gradiente descendente para que sejam ajustados. Em resumo, a RNA compara o valor de saída encontrado com o valor esperado e determina o erro decorrente das diferenças entre ambos. Assim, os pesos sinápticos são ajustados de forma a minimizar o erro, buscando-se a melhor relação entre as informações de entrada e saída (GUARNIERI, 2006). Sendo assim, o algoritmo contém duas fases: *forward* e *backward*. Na fase *forward*, os sinais que foram inseridos na entrada, propagam-se camada por camada até sua saída. Com isso, na fase *backward*, pode-se obter o erro enquanto os pesos sinápticos são ajustados conforme as camadas mais próximas da saída até a camada de entrada.

Neste exemplo da Figura 2 pode-se notar que a arquitetura contém três classes: A camada de entrada, onde entram os dados; a camada oculta (intermediária), que nesse exemplo são duas; e a camada de saída, que nesse caso se tem um único neurônio, ou seja, produz uma única informação em sua saída. Cada linha representada neste exemplo é uma conexão sináptica, com seu respectivo valor escalar que corresponde ao peso sináptico. A multiplicação entre os dados de entrada com os respectivos pesos sinápticos (W), resultam em um vetor o

qual é a entrada da camada oculta, podendo ser chamado de I por exemplo. Os dados então passam pela função de ativação (tangente hiperbólica). Faz-se a multiplicação por um novo conjunto de pesos sinápticos (W'), dando origem a um vetor I' . Novamente há um limiar de ativação para cada neurônio. Os dados então de I' são utilizados como entrada da camada de saída, onde aplica-se a função de ativação logística. O neurônio de saída é composto pelo vetor de saída Y .

Utilizando a figura 2 como exemplo, a etapa forward da MLP pode ser avaliado matematicamente pela equação (3):

$$Y = g_2(g_1(X \times W^T) \times W'^T) \quad (3)$$

em que:

Y representa o vetor de saída da rede neural;

g_1 e g_2 são as funções de ativação tangente hiperbólica e logística, respectivamente.

X são os vetores dos dados de entrada e;

W^T e W'^T representam as matrizes de pesos sinápticos transpostos.

Como os pesos sinápticos são ajustados na fase de *backward*, o processo de treinamento inicia-se pela camada de saída. Alguns métodos são utilizados para se tentar minimizar o erro. Um método de otimização de funções muito utilizado chama-se descendente (GARDNER; DORLING, 1998). Sua implementação segue os seguintes passos (BISHOP, 1995; SILVA; SPATTI; FLAUZINO, 2010):

Passo 1. Inicializar os pesos sinápticos da rede. Deseja-se que estes valores sejam pequenos e randômicos (GARDNER; DORLING, 1998);

Passo 2. Apresenta o primeiro vetor com os valores de entrada do treinamento, o qual é propagado até o fim da rede, obtendo-se um valor na saída;

Passo 3. Calcular o erro do sinal realizando a comparação entre o sinal obtido na saída com o desejado. Obtém-se o gradiente local do erro da camada de saída pela equação (4):

$$\delta_2 = (d - Y) \times g'(I') \quad (4)$$

em que:

δ_2 representa o vetor/matriz do gradiente local do erro da camada de saída;

d representa o vetor/matriz da saída desejada e;

$g'()$ é a função da derivada da função de ativação.

Passo 4. Pelo gradiente, pode-se calcular os pesos sinápticos entre a camada intermediária e a camada de saída, como demonstrado na equação (5).

$$W' = W' + \eta \times \delta_2 \times Y \quad (5)$$

em que:

η representa a taxa de aprendizagem;

Passo 5. Calcular o vetor/matriz gradiente (δ_1) relacionado com a camada de entrada e a intermediária, dado pela equação (6).

$$\delta_1 = (\delta_2 - W_2) \times g'(I) \quad (6)$$

Passo 6. Após obter o valor do gradiente, os pesos sinápticos de W são ajustados segundo a equação 7.

$$W = W + \eta \times \delta_1 \times X \quad (7)$$

Passo 7. Para o critério de parada, mensura-se o valor do erro entre a saída obtida e a saída desejada. Sendo p q quantidade de amostras, o erro quadrático médio é medido pela equação 8.

$$E_M = \frac{1}{p} \sum \left(\frac{1}{2} \sum (d - Y')^2 \right) \quad (8)$$

Passo 8. Enquanto não encontra-se um valor de erro aceitável, repetem-se os passos de 2 ao 8.

Para se determinar quando que a rede neural deve parar de rodar, pode-se escolher entre os mais usuais, como número de épocas, o erro e a parada antecipada (PRECHELT, 2012).

A parada pelo valor do erro, uma das mais utilizadas, faz com que o algoritmo encerre o treinamento uma vez que o erro encontrado pela rede fique abaixo de um valor pré-definido. Usualmente são escolhidos dois métodos para a análise do erro; o método do Erro Percentual Absoluto Médio (*Mean Absolute Percentual Error – MAPE*), no qual consiste na média dos erros absolutos percentuais (LOPES, 2002), ou seja, a somatória dos erros percentuais absolutos, dividido pelo período utilizado

para previsão. Para o cálculo do erro percentual absoluto, faz-se o número real de vendas no período, subtraído pela previsão de vendas nesse mesmo período, e este valor, dividido pelo número real de vendas no período. A equação 9 demonstra matematicamente o conceito.

$$MAPE = \frac{1}{n} \sum \left(\frac{|A(t) - F(t)|}{A(t)} \right) \quad (9)$$

em que:

$A(t)$ refere-se à demanda real no período t ;

$F(t)$ refere-se à previsão para o período t ;

n refere-se aos números de períodos de previsão t .

O outro método muito utilizado para análise do erro é o Erro Quadrático Médio (Mean Square Error – MSE), que é referente à média dos quadrados dos desvios entre demanda real e previsão (LOPES, 2002). O MSE é demonstrado matematicamente na equação 10.

$$MSE = \frac{1}{n} \sum (\hat{Y}_i - Y_i)^2 \quad (10)$$

em que:

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

Y_i é o valor fornecido para i -ésima amostra

Para poder utilizar os dados de entrada, antes, faz-se a normalização dos dados. Para isso, utilizou-se a regra dos mínimos e máximos, demonstrada na equação (11).

$$f(X) = \frac{X - Min}{Max - Min} \quad (11)$$

em que:

X é a amostra normalizada;

Min é o menor valor dentro do conjunto de dados;

Max é o maior valor dentro do conjunto de dados.

Existem dois tipos de erros que devem ser levados em conta e tomar o devido cuidado para não cometê-los. Os dois estão relacionados a redes superdimensionadas. Um deles se chama *overfitting*, que ocorre quando a rede

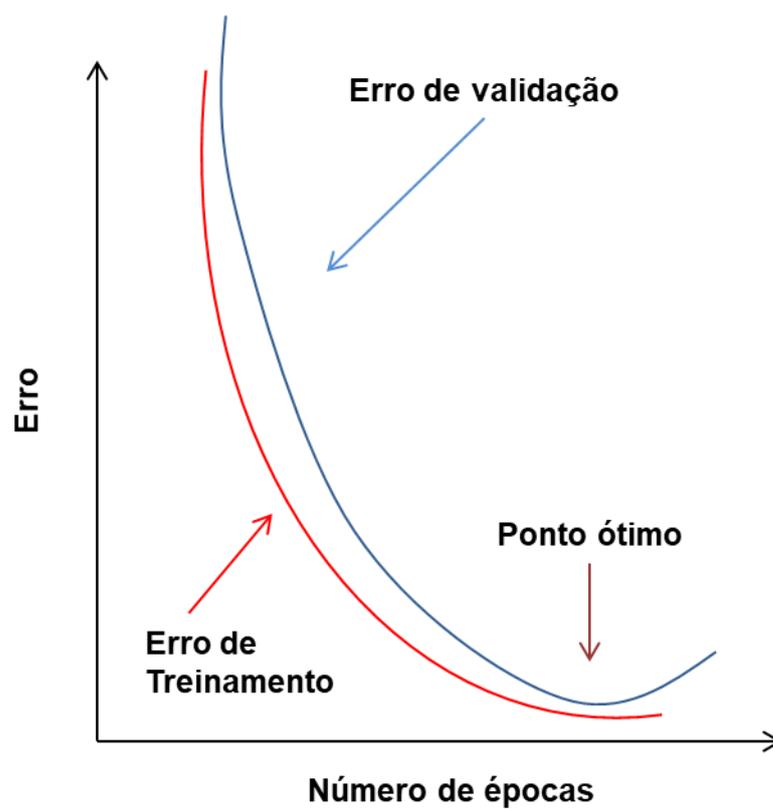
perde a capacidade de generalizar, pois ela memorizou os padrões de treino e perde a condição de previsão das saídas de pontos os quais não pertencem ao conjunto de treino. Isso acontece quando existe um número excessivo de neurônios ou camadas. Se o *overfitting* é o excesso de neurônios ou camadas, o *underfitting* é o contrário, quando a rede neural não foi suficientemente treinada para ser capaz de conseguir responder a resultados satisfatórios, ou seja, quando se tem um número muito baixo de neurônios na camada escondida ou de camadas para resolver o problema desejado. (ANDRADE, 2011).

Em relação a validação e análise de topologias, durante o treinamento o conjunto dos dados são divididos em dois grupos. O primeiro chama-se conjunto de treinamento, utilizado para o ajuste dos pesos sinápticos e potenciais de ação. O segundo chama-se conjunto de validação, onde analisa-se o desempenho da rede e sua capacidade de generalização (CHOJACZYK et al., 2010).

Para realizar a análise do desempenho de várias topologias de MLPs, a técnica de validação cruzada é uma das mais utilizadas. Com essa técnica, avalia-se a eficácia de cada rede ao ser aplicado o conjunto de validação. Para determinar qual será esse conjunto de dados, existem alguns métodos como: amostragem aleatória, por repartições (divide-se o conjunto de dados para serem validados) e por unidade (caso especial de repartições onde se usa apenas uma amostra por vez) (SILVA; SPATTI; FLAUZINO, 2010).

É relevante frisar a importância do ponto de parada do treinamento com o erro de validação, pois com essas informações pode-se encontrar o ponto ótimo de funcionamento da RNA. Sabe-se que o erro de treinamento é levemente menor que o erro de validação de uma MLP. Caso o erro de treinamento seja cada vez menor, é provável que a rede perca a capacidade de generalização, o que ocorre no aumento do erro de validação. A Figura 3 representa o conceito (SILVA; SPATTI; FLAUZINO, 2010).

Figura 3: Erros de treinamento e de validação por épocas



Fonte: Adaptado de Silva, Spatti e Flauzino (2010)

3 METODOLOGIA

Esta seção está dividida em 2 tópicos: Classificação da pesquisa e fases da pesquisa. Esse segundo está dividido em 5 sub-tópicos: Base escolhida e preparação dos dados; montagem da etapa de treinamento; teste de rede; análise dos resultados; discussão e considerações dos resultados.

3.1 CLASSIFICAÇÃO DA PESQUISA

Segundo Gil (2002), é possível que as pesquisas sejam classificadas em três grandes grupos: exploratórias, descritivas e explicativas.

Pesquisas exploratórias envolvem, em sua maioria, entrevistas com pessoas que tiveram contato na prática com o problema abordado; levantamento bibliográfico; análise de exemplos (SELLTIZ et al, 1967). Esse tipo de pesquisa tem por objetivo principal aprimorar ideias e descobrir intuições. Proporciona familiaridade com o problema – principalmente através dos exemplos – o que auxilia na construção das hipóteses (GIL, 2002).

O segundo tipo, pesquisas descritivas, servem para estabelecer relações entre variáveis, ou então, descrever características da população estudada, ou fenômenos. Inúmeros estudos são classificados como pesquisas descritivas, até pela padronização de coleta de dados, como questionários e observação sistemática por exemplo. Esse tipo de pesquisa, juntamente com as exploratórias, são as mais utilizadas por organizações, sejam partidos políticos, instituições educacionais, entre outras (GIL, 2002).

O último grupo em que se dividem os tipos de pesquisas, pesquisas explicativas, têm por preocupação identificar fatores que possam contribuir para ocorrência de fenômenos. Gil (2002) define essa pesquisa como “o tipo de pesquisa que mais aprofunda o conhecimento da realidade, porque explica a razão, o porquê das coisas. Por isso mesmo, é o tipo mais complexo e delicado, já que o risco de cometer erros aumenta consideravelmente”.

Baseado nesses conceitos, determinou-se que essa pesquisa tem cunho de pesquisa descritiva, uma vez que se baseia em dados históricos coletados em uma série temporal. Consegue-se com isso, determinar o quão eficiente é a rede neural na previsão de demanda de séries temporais.

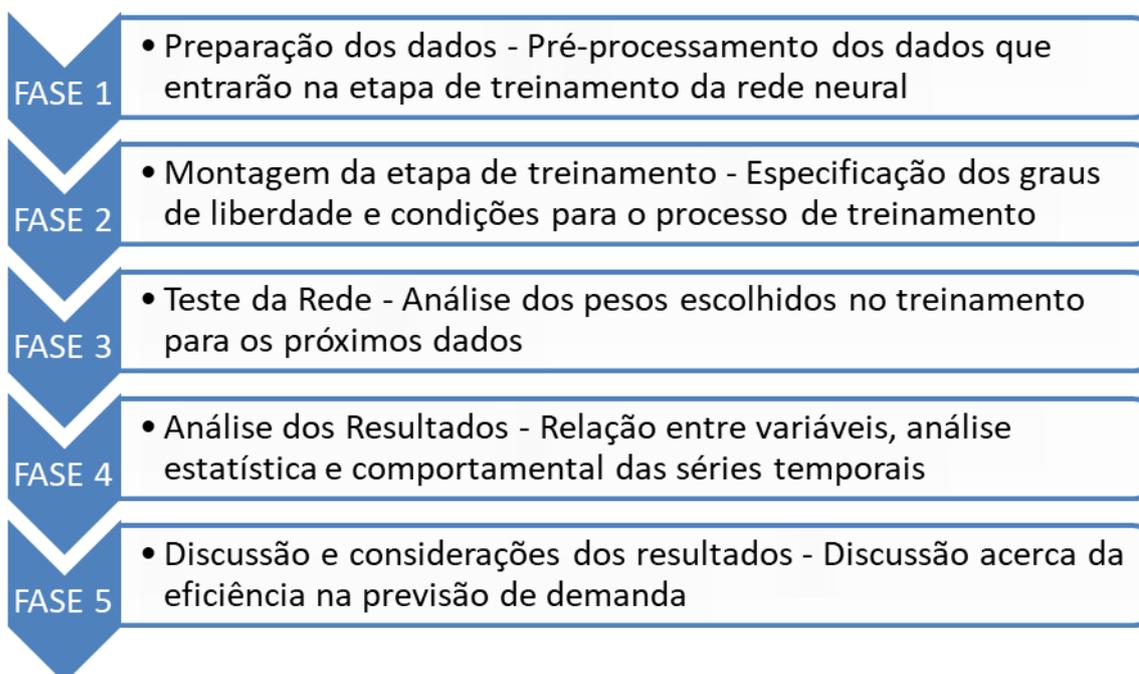
Existem outros dois grandes grupos em que se pode classificar a pesquisa, sendo eles, pesquisa qualitativa ou pesquisa quantitativa. Por vezes, a pesquisa acaba tomando um pouco dos dois, sendo chamada “quali-quantitativa”.

Segundo Flick (2000), uma das principais características da pesquisa qualitativa se refere à postura pessoal do pesquisador. Aceita-se explicitamente a influência de valores e crenças sobre a teoria, como por exemplo opiniões, emoções e sentimentos de pessoas à determinadas perguntas em um questionário. Já na pesquisa quantitativa, os “números falam por si só”, ou seja, a coleta e análise dos dados é feita de forma mais analítica e matemática – principalmente estatística – não sendo influenciada por crenças e valores pessoais. Sendo assim, essa pesquisa se classifica como quantitativa, uma vez que a coleta e análise dos dados de produção de automóveis no Brasil ao longo dos anos não sofre influência pessoal em crenças e valores.

3.2 FASES REALIZADAS NA PESQUISA

A pesquisa foi dividida em cinco fases. A Figura 4 as apresenta.

Figura 4: Fases realizadas na pesquisa



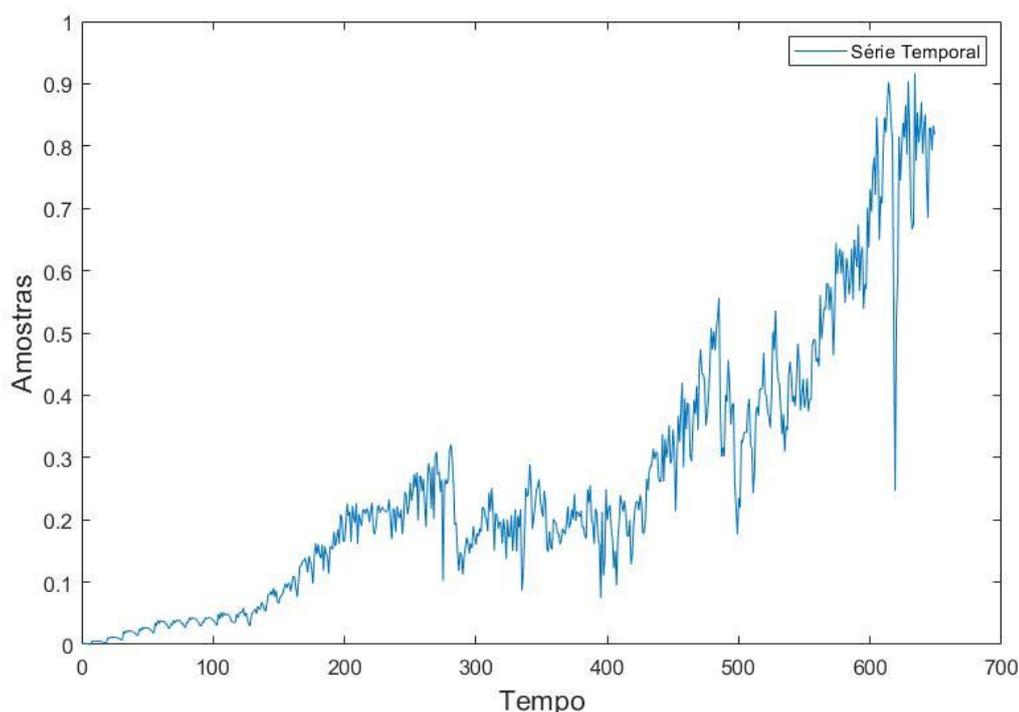
Fonte: Autoria própria

3.2.1 BASE ESCOLHIDA E PREPARAÇÃO DOS DADOS

A ANFAVEA disponibiliza em seu site oficial uma planilha de Excel, contendo todos os dados de licenciamento de autoveículos no Brasil – incluso aqui: automóveis, comerciais leves, caminhões e ônibus – desde janeiro de 1957, até os dias atuais onde é atualizado a cada final de mês.

Definiu-se então que os dados seriam em relação ao número de produção apenas de automóveis, pois esse é o foco do estudo. Os dados tomados foram do período de janeiro de 1957 até dezembro de 2015, totalizando 708 dados. Com essa quantidade de dados, acreditou-se ser suficiente para se ter um bom embasamento estatístico. Na etapa da pesquisa realizou-se o pré-processamento dos dados, onde foi feita a normalização dos dados, inspeção de possíveis ruídos nos mesmos e verificação se estão condizentes com a realidade. Esta etapa também pode ser chamada de tratamento dos dados. É uma etapa importante pois para a rede neural apresentar bons resultados, necessita de dados concisos como entrada para a parte de treinamento. A Figura 5 mostra o gráfico da série temporal utilizada como parâmetro para treinamento da MLP.

Figura 5: Série temporal



Fonte: Autoria própria

3.2.2 MONTAGEM DA ETAPA DE TREINAMENTO

Escolheu-se como forma de treinamento a forma supervisionada, na qual os dados os dados são apresentados com suas respectivas saídas. O algoritmo é o de *backpropagation*, em que se deseja encontrar o mínimo local ou global da função do erro entre entrada e saída.

Durante o treinamento os dados são estabelecidos em dois grupos principais: conjunto de treinamento, em que utiliza-se no ajuste dos pesos sinápticos e potenciais de ação. Para essa etapa separou-se 80% do conjunto total de dados. Determinou-se essa divisão conforme visto em trabalhos na literatura a usual escolha de divisão dos dados entre 70% e 90% do conjunto total de dados; e conjunto de validação, o qual é composto por amostras as quais são apresentadas aos pesos e limiares ajustados, com o intuito de analisar o desempenho da rede assim como sua capacidade de generalização. Para essa etapa, determinou-se 20% do conjunto total de dados.

3.2.3 TESTE DE REDE

Pelo *software* MATLAB® criou-se um algoritmo onde utilizou-se os 20% do conjunto total de dados para o conjunto de validação.

3.2.4 ANÁLISE DOS RESULTADOS

Obtendo os resultados estatísticos, demonstrou-se as tabelas e gráficos do treinamento, teste da rede e taxa de acerto.

3.2.5 DISCUSSÃO E CONSIDERAÇÕES DOS RESULTADOS

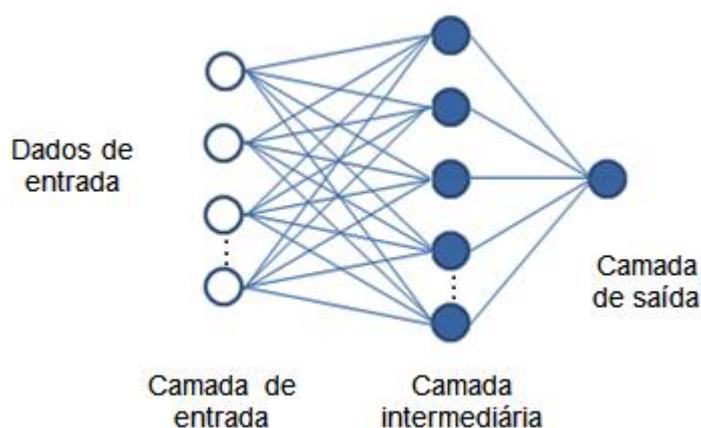
Com a demonstração de resultados, pôde-se analisar a taxa de acerto e inferir acerca da eficiência da MLP para a previsão de séries temporais, utilizando como estimador de erro o MSE e o MAPE.

4 DESENVOLVIMENTO DA REDE NEURAL ARTIFICIAL MLP

A MLP foi desenvolvida por meio de *scripts* no software MATLAB®. Os dados foram normalizados utilizando a regra de mínimos e máximos, conforme detalhado na seção 2.3.2.

Optou-se por desenvolver uma MLP com uma camada de entrada, uma camada oculta e uma camada de saída. Para esse tipo de problema de previsão de séries temporais com essa complexidade, a literatura mostra que essa topologia é o suficiente para obtenção de bons resultados. A Figura 6 mostra um exemplo da topologia da MLP utilizada, com n neurônios na camada de entrada, m neurônios na camada intermediária, e 1 neurônio na camada de saída.

Figura 6: Topologia da MLP

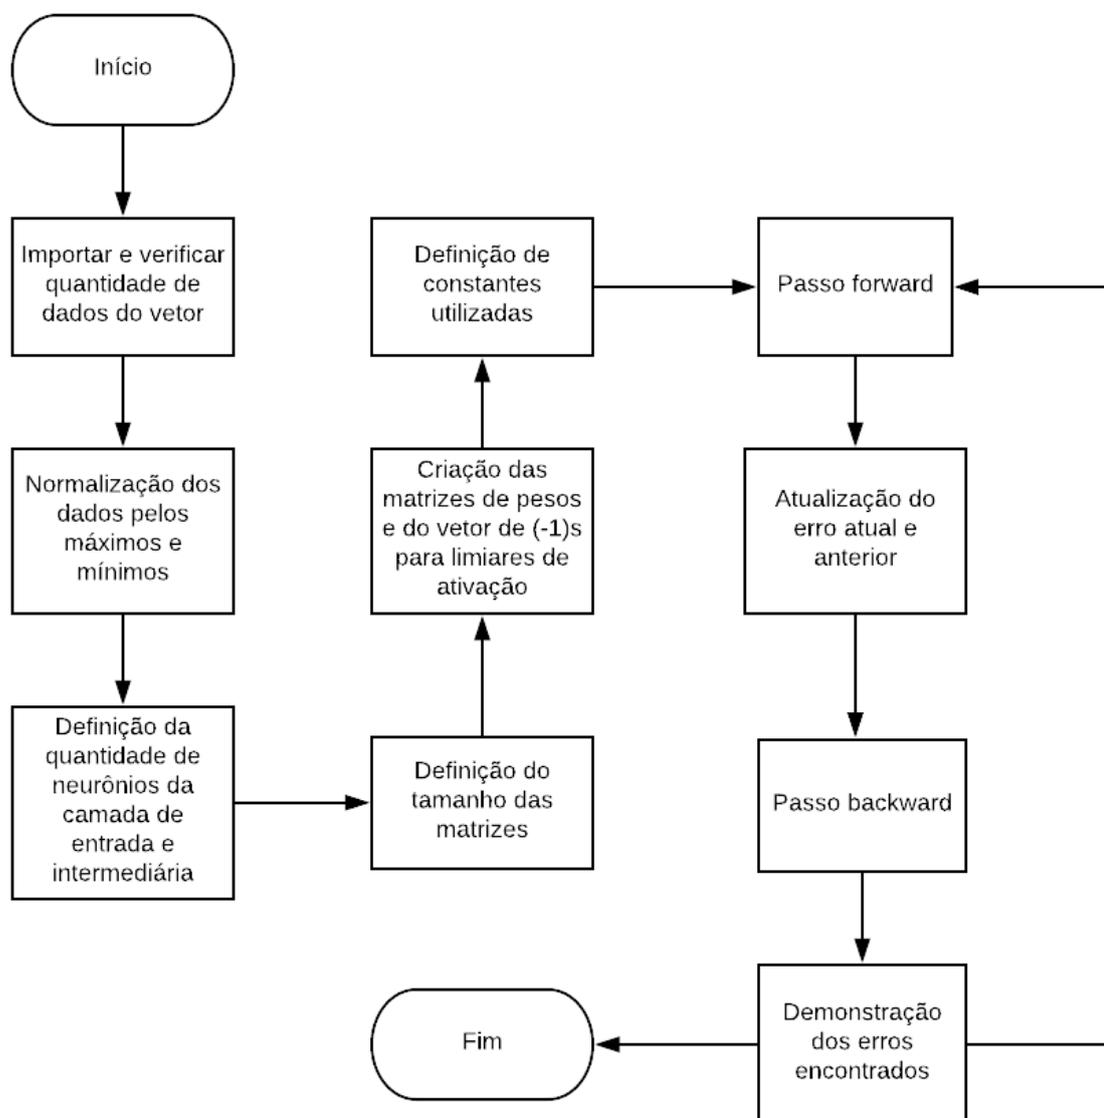


Fonte: Autoria própria

Para servir de dados de entrada para os neurônios das redes neurais, determinou-se uma abrangência de 10 anos. Por exemplo: coletar os dados entre 2005 e 2015, depois entre 1995 e 2015, e em seguida entre 1985 até 2015, e assim fazer com que a rede seja treinada com esses parâmetros. A cada 10 anos de dados coletados, fez-se uma parada e verificação do comportamento da rede neural e suas saídas, se correspondem com a realidade dos próximos anos ou não. Por exemplo: ao fazer a análise entre 2005 e 2015, verificou-se se a saída correspondeu com a realidade do ano de 2016 ou não.

A Figura 7 demonstra o passo-a-passo da etapa de treinamento da MLP.

Figura 7: Fluxograma do processo de treinamento da MLP



Fonte: Autoria própria

Primeiramente, os dados acerca do conjunto de dados referentes a produção de automóveis da ANFAVEA no período pré-estabelecidos são importados para o *software MATLAB®*, e verifica-se a quantidade de dados.

Faz-se então a normalização dos dados através do método de máximos e mínimos, previamente explicados. O passo seguinte é a definição da quantidade de neurônios na camada de entrada e camada intermediária.

Para realizar a análise foi escolhido um período de dois anos. Optou-se por esse período de análise pois considerou-se que com essa quantidade de dados dispostos referentes aos erros MAPE, MSE e absoluto traria uma boa confiabilidade

estatística ao estudo. Sendo assim, alterou-se no algoritmo os valores de neurônios de entrada de dois em dois, iniciando-se em 2 neurônios na camada de entrada, indo até 24 neurônios. De forma semelhante, trocou-se os valores dos neurônios da camada oculta, variando de cinco em cinco a partir de 5 neurônios na camada oculta e indo até 20 neurônios. Complementarmente, para se ter melhor embasamento estatístico, repetiu-se esse procedimento dez vezes para cada número de neurônio na camada de entrada e na camada oculta. Exemplo: 2 neurônios na camada de entrada e 5 neurônios na camada oculta. Rodou-se o algoritmo dez vezes e anotou-se os 10 erros (MAPE, MSE e erro absoluto) gerados.

Sabendo a quantidade de neurônios nas camadas de entrada e escondida, conforme foi-se alterando esses valores, foi possível o algoritmo determinar o tamanho das matrizes.

O próximo passo consiste na criação das matrizes de pesos e do vetor utilizado pelo limiar de ativação. Para a criação das matrizes de pesos sinápticos, os primeiros pesos (que entram na fase de treinamento) são gerados randomicamente, para o algoritmo então fazer o processo de alteração desses pesos buscando diminuir o erro, através da função de otimização gradiente descendente, conforme explicado anteriormente. De forma semelhante os pesos sinápticos entre a camada intermediária e a de saída também são gerados de forma randômica.

Algumas constantes foram determinadas no passo seguinte, como por exemplo, os critérios de parada. Nesse caso optou-se por dois critérios: um em relação a precisão do erro, o qual caso fosse menor ou igual a $0.5n$ (elevado a nona potência negativa) o algoritmo encerraria o processo. Outro critério foi em relação ao número de épocas. Caso o algoritmo ultrapasse o valor de 300 mil épocas, o processo também seria parado.

Para fazer a análise dos resultados obtidos pela rede, verificou-se a taxa de acerto em relação aos parâmetros de MAPE, MSE e absoluto, obtendo a média das médias em relação a todos os dados gerados, tanto para diferentes números de neurônios de entrada quanto para diferentes números de neurônios na camada oculta.

A taxa de aprendizagem escolhida foi de 0,1, sendo ela uma constante positiva referente à velocidade de aprendizado da rede. Essa taxa é um parâmetro importante pois pode influenciar nos resultados apresentados pela MLP. Ela não deve ser nem muito pequena, ocasionando um treinamento muito lento, nem muito

grande, podendo gerar oscilações. Quando a taxa de aprendizado é muito pequena, a RNA pode estagnar em um mínimo local. Em contrapartida quando essa taxa é grande, a RNA pode não conseguir convergir ao mínimo global por conta dos valores dos pesos serem grandes.

Os últimos passos são formados em forma de *looping*, uma vez que após o passo *forward*, atualiza-se os erros atuais e anteriores, onde após isso começa o passo chamado *backward*, onde os pesos são ajustados afim de diminuir o erro encontrado. Assim, retorna-se ao passo *forward*, se estendendo nesse ciclo até o algoritmo encontrar o mínimo global, ou a o critério de parada ser executado.

As principais características e constantes utilizadas para criação e treinamento da MLP são descritas na tabela 2.

Tabela 2 – Principais características da MLP

Parâmetro	Valor	Considerações
np = quantidade de neurônios na camada de entrada	np = 2~24	Variou-se os números de neurônios entre 2 e 24.
n1 = número de neurônios na camada escondida	n1 = 5 e 20	Variou-se os números de neurônios entre 5 e 20.
Função de ativação da camada escondida	Tangente hiperbólica	Função diferenciável usada para estimar o primeiro conjunto de pesos, podendo assumir valores entre -1 e 1.
Função de ativação da camada de saída	Logística	Função diferenciável que assume valores entre 0 e 1.
b = inclinação das funções tangente hiperbólica e logística	b=0,5	Essa inclinação para ambas as funções permite selecionar um valor para equilibrar o uso da função matemática, evitando o saturamento do neurônio.
W1 =primeiro conjunto de pesos	Matriz(n1 x np+1)	Pesos sinápticos entre a camada de entrada e a escondida gerada com números aleatórios
W2 = Segundo conjunto de pesos	Matriz(1 x np+1)	Pesos sinápticos aleatórios entre a camada escondida e a de saída, gerada com números aleatórios positivos
Tx = taxa de aprendizagem	Tx = 0.1	Constante positiva que corresponde à velocidade do aprendizado

e = precisão do erro	$e=5n$	Precisão do erro médio quadrático usado como critério de parada do treinamento
época	Parada com 300000	Quantidade de vezes que o Sistema apresenta todas as amostras durante o treinamento. Usado como critério de parada do treinamento ao atingir 300000 épocas

Fonte: Autoria Própria

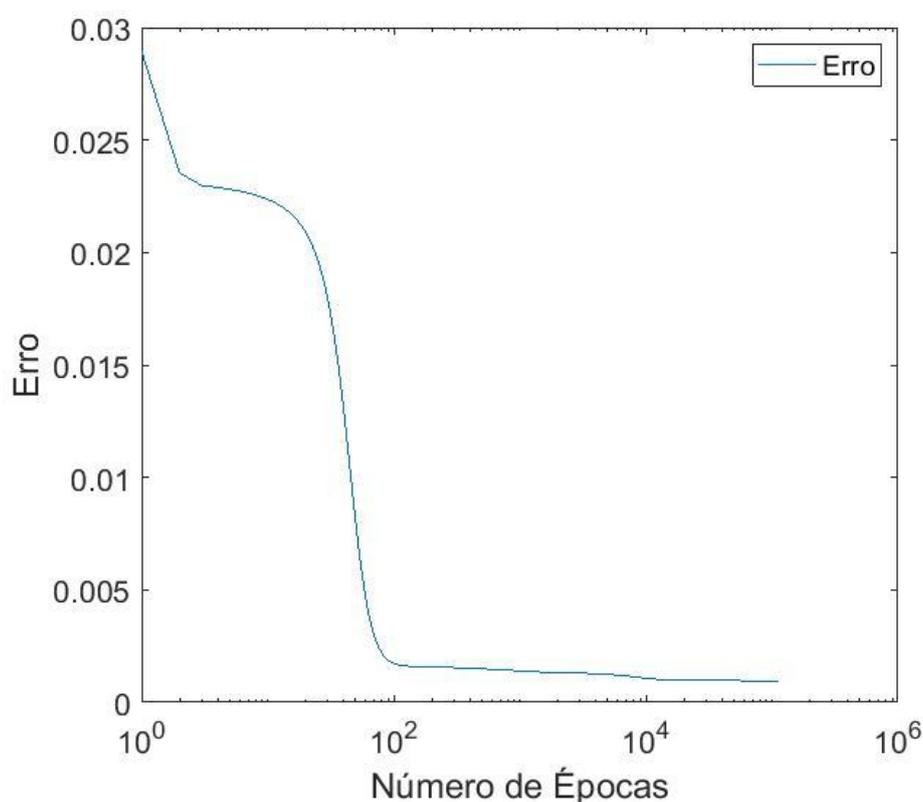
Conforme a rede neural foi sendo treinada, a saída gerada foi utilizada como entrada para uma próxima bateria de testes, sendo assim feito o processo de aprendizagem, correção de erros e generalizações, processo comentado anteriormente, chamado de *feedforward*.

5 RESULTADOS E DISCUSSÕES

Nesta seção apresenta-se os resultados relacionados aos testes realizados com a Rede Neural Artificial, bem como taxa de acerto e comparações entre os erros obtidos.

Na Figura 8, demonstra-se o comportamento do erro, que pôde ser observado ao longo do treinamento da MLP. Percebe-se que há um decréscimo do erro aproximando-se de um ponto próximo a zero, convergindo ao erro da função, significando a busca do mínimo local da função através do método do gradiente.

Figura 8: Gráfico do erro pelo número de épocas no treinamento da MLP



Fonte: Autoria Própria

Assim como comentado anteriormente, anotou-se o erro MAPE, MSE e o erro absoluto entre diferentes números de neurônios nas camadas de entrada e intermediária, rodando o código dez vezes para cada um. As Tabelas 3 e 4 demonstram como os resultados foram registrados, e a média das dez anotações de cada um deles. Para uma melhor visualização, os números de 1 a 10 foram colocados arredondados com duas casas decimais. Já a média mostra um valor

mais preciso com três casas decimais. Como exemplo, pegou-se o primeiro teste, com 2 neurônios na camada de entrada, e o último teste, com 24 neurônios na camada de entrada.

Tabela 3 – Comparação de erros com 2 neurônios na camada de entrada

2 neurônios de entrada	1	2	3	4	5	6	7	8	9	10	Média
5 neurônios na camada oculta											
MAPE	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,070
MSE	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,017
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001
10 neurônios na camada oculta											
MAPE	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,071
MSE	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,017
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001
15 neurônios na camada oculta											
MAPE	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,073
MSE	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,014
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001
20 neurônios na camada oculta											
MAPE	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,073
MSE	0,01	0,01	0,01	0,02	0,01	0,02	0,02	0,02	0,01	0,01	0,015
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001

Fonte: Autoria Própria

Tabela 4 – Comparação de erros com 24 neurônios na camada de entrada

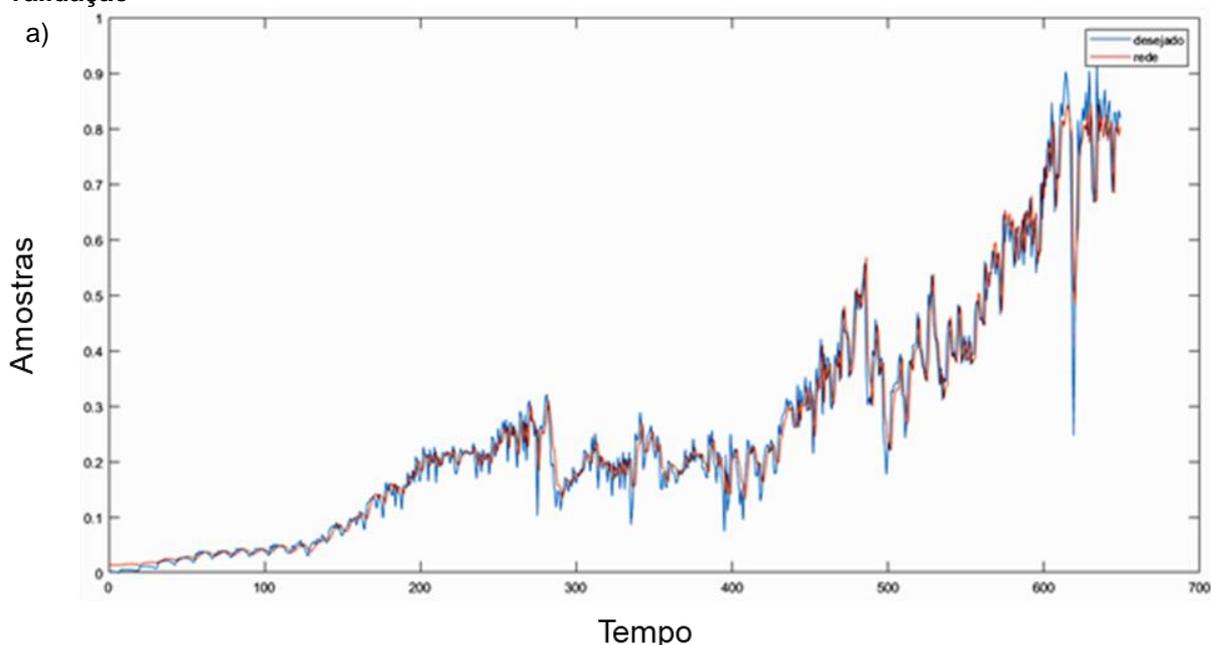
24 neurônios de entrada	1	2	3	4	5	6	7	8	9	10	Média
5 neurônios na camada oculta											
MAPE	0,09	0,09	0,09	0,09	0,09	0,09	0,09	0,09	0,09	0,09	0,090
MSE	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,009
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001
10 neurônios na camada oculta											
MAPE	0,07	0,07	0,09	0,10	0,09	0,07	0,09	0,09	0,09	0,07	0,071
MSE	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,007
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001
15 neurônios na camada oculta											
MAPE	0,09	0,09	0,09	0,09	0,08	0,09	0,09	0,09	0,08	0,09	0,089
MSE	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,010
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001
20 neurônios na camada oculta											
MAPE	0,08	0,08	0,09	0,08	0,08	0,07	0,07	0,07	0,08	0,09	0,080
MSE	0,01	0,01	0,01	0,02	0,01	0,02	0,02	0,02	0,01	0,01	0,012
Erro	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,001

Fonte: Autoria Própria

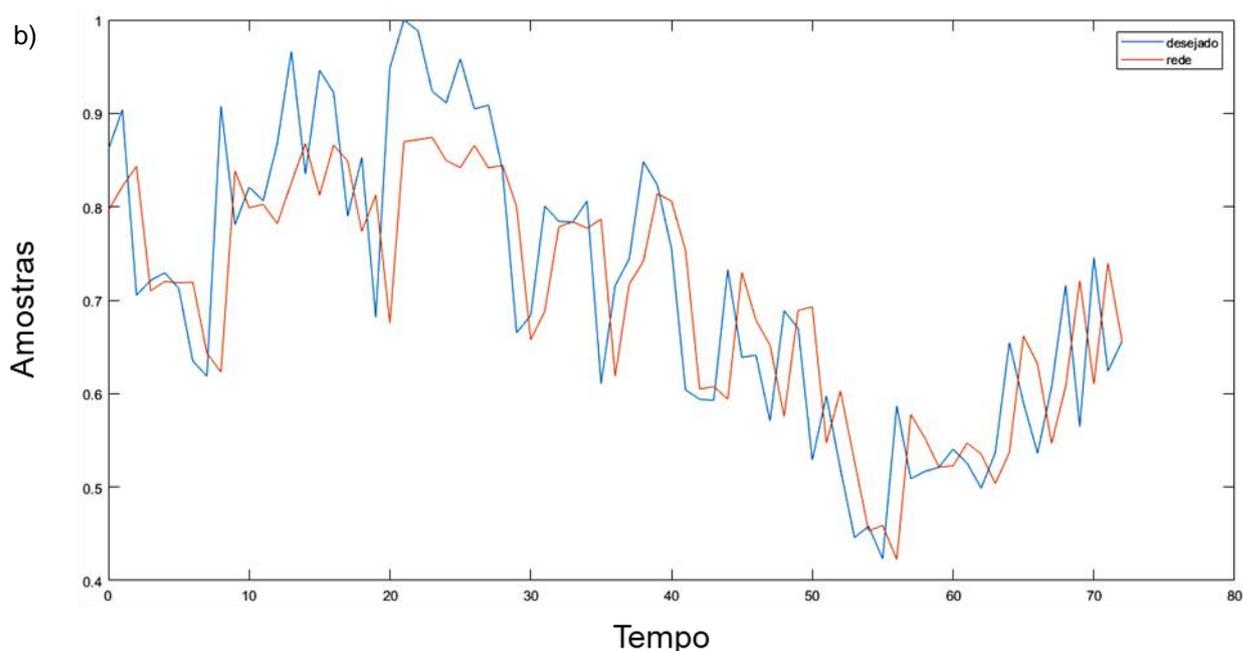
Interessante analisar que conforme houve o aumento do número de neurônios na camada de entrada, os valores de MAPE e MSE apresentaram diferentes variações. Com esse aumento, o MAPE aumentou o valor do erro obtido. Em contrapartida, ao se aumentar o número de neurônios na camada de entrada, o MSE diminuiu de patamar. Pode-se inferir essa disparidade pelas diferenças entre as equações matemáticas, demonstradas na sessão 2.3.2, equações (9) e (10). Em relação ao MAPE, a equação é realizada com os valores de demanda real e previsão do quanto era esperado para o período. Já o MSE, trabalha com o quadrado da diferença entre a média dos valores de todas as amostras e a amostra no instante n .

Por fim, a partir da divisão dos dados, a Figura 9 demonstra os resultados em relação aos 80% de dados usados para treinamento (a) e os 20% usados para teste/validação (b). Verifica-se o quanto era esperado de resultado (em azul) e o quanto a rede neural previu (vermelho).

Figura 9: Gráfico Amostras por Tempo em que a) dados de treinamento e; b) dados de validação



Fonte: Autoria Própria



Fonte: Autoria Própria

Criou-se a Tabela 5 para uma melhor visualização dos resultados em relação à taxa de acerto:

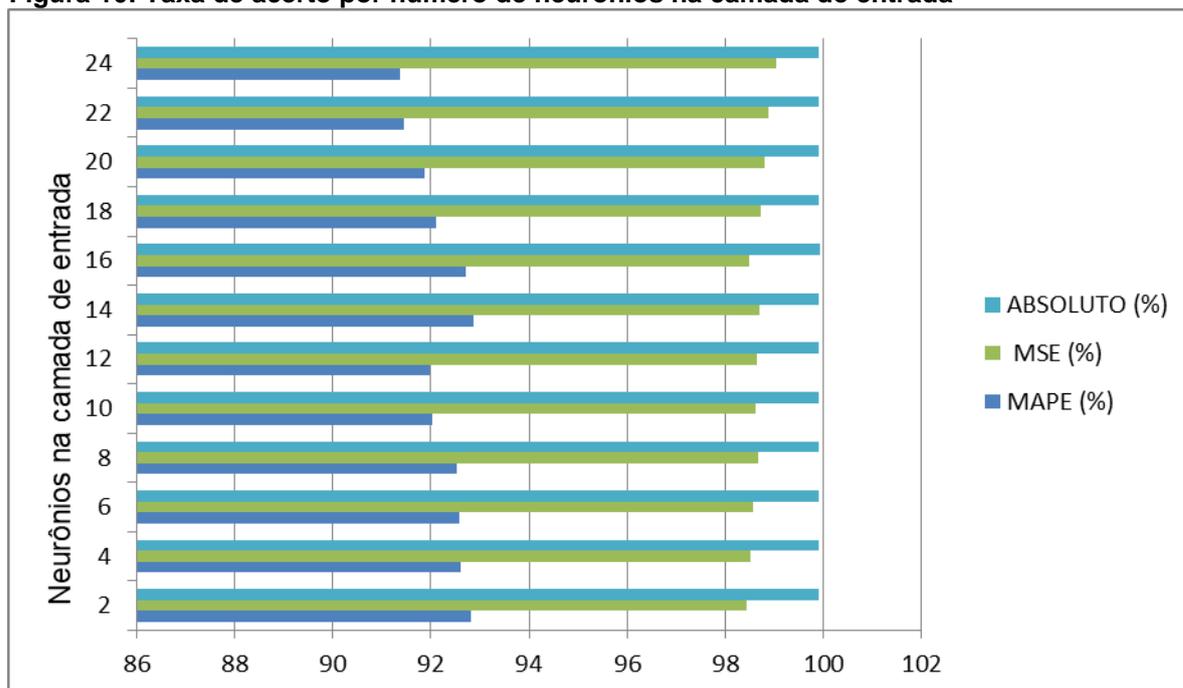
Tabela 5 – Taxa de acerto por número de neurônios na camada de entrada

Neurônios na camada de entrada	MAPE (%)	MSE (%)	ABSOLUTO (%)
2	92,83	98,43	99,90
4	92,62	98,52	99,90
6	92,58	98,57	99,90
8	92,52	98,68	99,90
10	92,04	98,61	99,91
12	91,97	98,64	99,91
14	92,88	98,69	99,91
16	92,71	98,48	99,92
18	92,10	98,73	99,91
20	91,88	98,81	99,91
22	91,46	98,87	99,91
24	91,37	99,05	99,91
Média	92,25	98,67	99,91

Fonte: Autoria Própria

Com esses dados acerca da taxa de acerto, criou-se o gráfico da Figura 10 para uma melhor percepção da dispersão dos erros.

Figura 10: Taxa de acerto por número de neurônios na camada de entrada



Fonte: Autoria Própria

Pode-se perceber, com os resultados obtidos através do *software*, a tabela e os gráficos mostrados anteriormente, que a Rede Neural Artificial MPL apresentou bom desempenho com relação à previsão de dados, obtendo uma taxa de acerto acima de 92%.

É sabido que quanto maior a quantidade de dados – e, uma vez que os números estejam corretos (normalizados) – a MLP tende a ter um treinamento mais “completo”, com uma maior aprendizagem, o que resulta em uma melhor taxa de acerto na previsão.

6 CONSIDERAÇÕES FINAIS

É relevante salientar a importância das Inteligências Artificiais no cotidiano que vivemos. Essa ferramenta tecnológica avança de forma muito acelerada para auxiliar nos diversos setores industriais, e de diversas formas impactando a vida das pessoas não só economicamente mas também como na saúde – estudos sobre classificações e previsões de câncer, e diagnósticos de doenças do coração são alguns exemplos.

De forma geral, este trabalho conseguiu realizar todos os objetivos específicos estabelecidos.

Primeiramente, apresentou-se todo um referencial teórico acerca da importância do setor automobilístico para o país, com sua história, presente e perspectiva futura. Em seguida, contemplou-se a explicação acerca das Redes Neurais Artificiais e como se dá seu funcionamento para previsão de séries temporais.

Após essa etapa, determinou-se a topologia a ser utilizada e demonstrou-se toda a metodologia de como foi realizada a preparação dos dados, treinamento, teste, validação e obtenção dos resultados da RNA MLP.

Por fim, discutiu-se sobre os resultados obtidos com a análise dos indicadores de taxa de acerto em relação ao MSE E MAPE, e chegou-se a conclusão da eficácia da MLP na previsão de séries temporárias, que para esse problema, foi positivo e realizado com êxito.

Por fim, se mostra relevante destacar também, que a MLP hoje, como dito anteriormente, é uma excelente ferramenta de auxílio à tomada de decisão. Entretanto, o fator humano ainda se faz necessário. É importante que o ser humano possa ser auxiliado pela MLP, mas que tenha o controle sobre sua decisão final. A MLP ainda não consegue prever algumas nuances devido à aspectos sociais e econômicos que permeiam a nossa realidade e a sociedade que vivemos.

Uma vez que a previsão de demanda pode se estender para tantas outras áreas que não só a automobilística, e igualmente para outros países, este trabalho pode vir a servir de apoio para futuros estudos e pesquisas acerca da usabilidade da MLP na previsão de séries temporais.

REFERÊNCIAS

ABERJE (Associação Brasileira De Comunicação Empresarial). **Seis países europeus anunciam que vão banir o carro a combustão até 2040**. Disponível em: <<http://www.aberje.com.br/seis-paises-europeus-anunciam-que-vaio-banir-o-carro-combustao-ate-2040/>>. Acesso em: 13 out. 2017.

ALMEIDA, C.C.R.; CARIO, S.A.F.; MERCÊS, R.; GUERRA, O.F. **Indústria automobilística brasileira: conjuntura recente e estratégias de desenvolvimento**. Indicadores Econômicos. FEE, Porto Alegre, v. 34, n.1, p.165-152, jan./mar. 2006.

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.

ANFAVEA (Associação nacional dos fabricantes de veículos automotores). **Anuário Estatístico da Indústria Automobilística Brasileira**. São Paulo: ANFAVEA, 2014.

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

BASHEER, I. A.; HAJMEER, M. **Artificial neural networks: fundamentals, computing, design, and application**. Journal of Microbiological Methods, Neural Computing in Micrbiology. v. 43, n. 1, p. 3–31, 1 dez. 2000

BNDES (Banco Nacional de Desenvolvimento Econômico e Social). **Capacidade produtiva das montadoras**. São Paulo. BNDES, 2015.

BRAGA, A.P.S; CARVALHO, A.P.L.F; LUDERMIR, T.B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: LTC, 2012.

BOTELHO, A. **Reestruturação produtiva e produção do espaço. O caso da indústria automobilística instalada no Brasil**. Revista do departamento de Geografia, São Paulo, v. 15, p.55-64, 2002.

BOX, P.; JENKINS, G.M. **Time series analysis: forecasting and control**. San Francisco, CA: Holden-day Inc, 1976.

CHOJACZYK, A. A. et al. **Review and application of Artificial Neural Networks models in reliability analysis of steel structures**. Structural Safety, v. 52A, p. 78–89, 2010.

CHOI, T. Y.; KRAUSE, D. R. **The supply base and its complexity: Implications for transaction costs, risks, responsiveness, and innovation**. Journal of Operation Management, v.24, p.637-652, 2006.

CORREIA, João Carlos. **Impactos da indústria automobilística nas cidades do Estado de São Paulo e suas transformações em função do processo industrial**. Tese (Doutorado) Universidade de São Paulo, São Paulo, 2008.

FAVARETTO, F. **Impacto das incertezas da previsão da demanda no planejamento detalhado da produção**. P&D em Engenharia de Produção, Itajubá, v.10, n.1, p. 101-108, 2012.

FENABRAVE (Federação Nacional da Distribuição de Veículos Automotores). **Anuário Estatístico da Distribuição de Veículos Automotores** São Paulo: FENABRAVE, 2016.

FENABRAVE (Federação Nacional da Distribuição de Veículos Automotores). **Tesla é montadora mais valiosa dos EUA**. Disponível em: <<http://www3.fenabrave.org.br:8082/plus/modulos/noticias/ler.php?cdnoticia=9518&cdcategoria=1&layout=noticias>>. Acesso em: 23 set. 2017.

FITCH RATINGS. **Fitch Rebaixa Ratings do Brasil Para 'BB-'**. Disponível em: <<https://www.fitchratings.com.br/publications/10674>>. Acesso em: 22 set. 2017.

FLICK, U. Entrevista episódica. Em M. W. Bauer & G.Gaskell, G. (Orgs.), **Pesquisa qualitativa com texto, imagem e som: um manual prático** (pp. 114-136). (P. A. Guareschi, Trad.). Petrópolis: Vozes (Original publicado em 2000).

GARDNER E. S. **Exponential smoothing: the state of the art**. Journal of Forecasting, 4: 1–28, 1985.

GARDNER, M. W.; DORLING, S. R. **Artificial neural networks (the multilayer perceptron)** — a review of applications in the atmospheric sciences. *Atmospheric Environment*, v. 32, n. 14–15, p. 2627–2636, 1 ago. 1998.

GERBER, J. Z., MIRANDA, R. G., BORNIA, A. C., FREIRES, F. G. M. **Organizações de referencial teóricos sobre diagnóstico para a previsão da demanda.** *Revista Eletrônica de Gestão Organizacional – UFPE*, 2013.

GIL, A. C.. **Como elaborar projetos de pesquisa.** 4 ed. São Paulo: Atlas, 2002.

GOVERNO DO BRASIL. **Rota 2030 vai fortalecer e modernizar a indústria automobilística nacional.** Disponível em: <<http://www.brasil.gov.br/noticias/economia-e-financas/2018/07/rota-2030-vai-fortalecer-e-modernizar-a-industria-automobilistica-nacional>>. Acesso em: 13 ago. 2018.

GRIPPA, D. B., LEMOS, F. O., FOGLIATTO, F. S. Analogia e combinação de previsões aplicados à demanda de novos produtos. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 25., 2005, Porto Alegre. **Anais...** Porto Alegre.

HAYKIN, S. **Redes Neurais Princípios e prática.** 2. ed. Porto Alegre: Bookman, 2001.

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

HYNDMAN, R.J; MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; **Forecasting: methods and applications.** 3ª ed. United States of America: Ed. Wiley & Sons, 1988, 642 p.

HEUTS, R. M. J., & BRONCKERS, J. H. J. M. **Forecasting the Dutch heavy truck market: A multivariate approach.** *International Journal of Forecasting*, 4, 57– 79, 1988.

HUANG, G.-B; ZHU, Q.-Y; QIN, A.K; SUGANTHAN P.N. **Evolutionary Extreme Learning Machine, Pattern Recognition.** 38, 1759-1763 (2005).

HOLWEG, M., MIEMCZYK, J. **Delivering the '3-day car' – the strategic implications for automotive logistic operations**. Article Journal of Purchasing and Supply Management, Volume 9, Issue 2, March 2003, p. 63-71.

IBGE (Instituto Brasileiro de Geografia e Estatística). **Anuário Estatístico da Indústria no Brasil**. São Paulo: IBGE, 2017.

KEEN, P. G. W. **Guia Gerencial para a tecnologia da informação: Conceitos essenciais e terminologia para empresas e gerentes**. Rio de Janeiro: Campus, 1996.

KUPFER, D. **Trajetórias de Reestruturação da Indústria Brasileira após a abertura e Estabilização**. Tese de Doutorado. Instituto de Economia/UFRJ. RJ, 1998.

KURRLE, M. A. **Métodos para previsão de demanda de veículos novos** – Estudo de caso em uma concessionária de automóveis. Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul / Escola de Engenharia / Mestrado Profissional em Engenharia. Porto Alegre-RS, 2004.

KAZMIER, L.. J. **Princípios de gerência**. 2. ed. Rio de Janeiro: Pallas, 1975.

LATINI, S. A. **A implantação da indústria automobilística no Brasil: da substituição de importações ativa à globalização passiva**. São Paulo: Alaúde Editorial, 2007.

LIN, T. Y., AMARAL, J. B. C. **Estudo de modelos de previsão de demanda**. Relatório do Programa Institucional de Bolsas de Iniciação Científica (Fundação Getúlio Vargas), São Paulo, 2005.

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.

LOLLI, F; R. GAMBERINI; A. REGATTIERI; E. BALUGANI; T. GATOS; S. GUCCI. **Single-hidden layer neural networks for forecasting intermitente demand**. International Journal of Production Economics, 2017.

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

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. The bulletin of mathematical biophysics, v. 5, n. 4, p. 115–133, 1943.

MORETTIN, P.A.; TOLOI, C.L.C. **Análises de séries temporais**. São Paulo: Edgard Blucher, 2004.

NETO, M.; PIRES, S. R. I. **Organização da produção, desempenho e inovações na cadeia de suprimentos da indústria automobilística brasileira**. Revista de Ciências da Administração, v. 9, n. 19, p. 34-53, 2007.

OICA (Organização Internacional de Construtores Automotivos). **Anuário Estatístico da Produção Automobilística Mundial**. Paris: OICA, 2016.

PALIT, A. K., POPOVIC, D., **Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications**, London, Springer, 2005.

PIANI, Guida; MIRANDA, Pedro. **Regimes especiais de importação e "ex-tarifários"**: o caso do Brasil. Rio de Janeiro: Ipea, 2006.

PIMENTA, Luiz José. **A crise na rede concessionárias de automóvel no Brasil**. Dissertação (Mestrado) – Universidade Salvador – UNIFACS – Bahia 2002.

PELLEGRINI, F. R., FOGLIATTO, F. S. **Estudo comparativo entre modelos Winters e de Box-Jenkins para previsão de demanda sazonal**. Artigo do Programa de Pós-Graduação em Engenharia de Produção – UFRGS, 2001.

PELLEGRINI, F. R., FOGLIATTO, F. S. Metodologia para implantação de sistemas de previsão de demanda – técnicas e estudo de caso. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 21., 2001, Salvador. **Anais...** Salvador.

POSSAS, M.L. **Estruturas de Mercado em oligopólio**. São Paulo: Hucitec, 1985.

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

RODRIGUES, G. G., PIZZOLATO, N. D. Centros de distribuição: armazenagem estratégica. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 23., 2003, Ouro Preto. **Anais...** Ouro Preto.

SELLTIZ, Claire et. ai. **Métodos de pesquisa nas relações sociais**. São Paulo: Herder, 1967.

SILVA, Christian. **As estratégias da indústria automobilística brasileira**. Net, revista Business, n2, jun. 2002.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo: Artiliber, 2010.

SOUZA, R. C., CAMARGO, M. E. **Análise e Previsão de Séries Temporais: Os Modelos ARIMA**. 2ª Ed., 2004.

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

ZANINI, A. **Redes Neurais e Regressão Dinâmica**: Um Modelo Híbrido para Previsão de Curto Prazo da Demanda de Gasolina Automotiva no Brasil. Dissertação de Mestrado, PUC-Rio, DEE, 2000.