

UNIVERSIDADE DE CAXIAS DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

SIDIMAR CAPITANIO

**DESENVOLVIMENTO DE ALGORITMO ADAPTÁVEL UTILIZANDO REDES
NEURAIS ARTIFICIAIS PARA PREVISÃO DE DEMANDA**

BENTO GONÇALVES

2019

SIDIMAR CAPITANIO

**DESENVOLVIMENTO DE ALGORITMO ADAPTÁVEL UTILIZANDO REDES
NEURAS ARTIFICIAIS PARA PREVISÃO DE DEMANDA**

Dissertação de Mestrado apresentada como requisito parcial para a obtenção do título de Mestre em Engenharia de Produção no Programa de Pós-graduação em Engenharia de Produção da Universidade de Caxias do Sul.

Orientadora: Profa. Dra. Maria Emília Camargo

**BENTO GONÇALVES
2019**

Dados Internacionais de Catalogação na Publicação (CIP)
Universidade de Caxias do Sul
Sistema de Bibliotecas UCS - Processamento Técnico

C244d Capitanio, Sidimar

Desenvolvimento de algoritmo adaptável utilizando redes neurais artificiais para previsão de demanda / Sidimar Capitanio. – 2019.

65 f. : il. ; 30 cm

Dissertação (Mestrado) - Universidade de Caxias do Sul, Programa de Pós-Graduação em Engenharia de Produção, 2019.

Orientação: Maria Emília Camargo.

1. Algoritmos. 2. Planejamento da produção. 3. Redes neurais (Computação). 4. Associações, instituições, etc.. 5. Inteligência artificial. I. Camargo, Maria Emília, orient. II. Título.

CDU 2. ed.: 004.421

Catalogação na fonte elaborada pela(o) bibliotecária(o)
Michele Fernanda Silveira da Silveira - CRB 10/2334

SIDIMAR CAPITANIO

**DESENVOLVIMENTO DE ALGORITMO ADAPTÁVEL UTILIZANDO REDES
NEURAS ARTIFICIAIS PARA PREVISÃO DE DEMANDA**

Dissertação de Mestrado apresentada como requisito parcial para a obtenção do título de Mestre em Engenharia de Produção no Programa de Pós-graduação em Engenharia de Produção da Universidade de Caxias do Sul.

Aprovado em 25/06/2019

BANCA EXAMINADORA

Profª. Dra. Maria Emília Camargo
Universidade de Caxias do Sul - UCS

Profª. Dra. Cintia Paese Giacomello
Universidade de Caxias do Sul - UCS

Prof. Dr. Leonardo Dagnino Chiwiacowsky
Universidade de Caxias do Sul – UCS

Prof. Dr. Luís Felipe Dias Lopes
Universidade Federal de Santa Maria – UFSM

Profª. Dra. Suzana Leitão Russo
Universidade Federal de Sergipe - UFS

Dedico este trabalho ao meu filho Maikel. Aos meus pais Ari e Maria, pelo incentivo e esforço para tornar este momento uma realidade. À meu irmão Sidinei pelos conselhos e apoio. À minha esposa Bianca por estar sempre ao meu lado, mostrando companheirismo e apoio incondicional. Aos colegas, professores e amigos.

AGRADECIMENTOS

À Deus por ter me dado saúde e força para superar as dificuldades.

À minha família pelo apoio, incentivo e esforço, tendo eles como exemplo.

À minha esposa Bianca pela compreensão, apoio e paciência que foram fundamentais para a realização deste trabalho.

À minha orientadora Profa. Dra. Maria Emilia Camargo e meu professor da disciplina de Planejamento e Controle da Produção Prof. Dr. Gabriel Vidor pelas sugestões, orientações e conhecimento adquirido.

Ao professor da disciplina de Modelagem I/II, Dr. Leonardo Dagnino Chiwiacowsky, pelas sugestões diretamente relacionadas ao trabalho da dissertação.

Ao amigo Vinícius Denardi pela colaboração na solução de problemas dos softwares envolvidos.

Ao Professor Jones que concedeu muitas dicas para melhorias do trabalho realizado.

Ao corpo Docente da Universidade de Caxias do Sul, campus de Bento Gonçalves, e aos professores que passaram seus ensinamentos em minha formação inicial, fundamental, ensino médio e graduação.

Aos meus amigos que de alguma forma sempre auxiliaram na minha vida acadêmica.

“Deixem que o futuro diga a verdade e avalie cada um de acordo com o seu trabalho e realizações. O presente pertence a eles, mas o futuro pelo qual eu sempre trabalhei pertence a mim.”

Nikola Tesla

RESUMO

A previsão de demanda é uma ferramenta importante para qualquer setor do mercado de trabalho, com a qual as organizações fazem sua gestão e planejamento baseando-se na predição futura de suas variáveis envolvidas. A previsão de demanda possui variadas formas e métodos de gerar uma predição, portanto, o presente trabalho tem como objetivo o desenvolvimento de um algoritmo de previsão de demanda adaptável aos dados das organizações, podendo-se modelar e atribuir variáveis do processo que influenciam diretamente na predição. O modelo de previsão é baseado em uma abordagem de aprendizado de máquina, que se deu com o desenvolvimento de uma Rede Neural Artificial (RNA), a qual para o seu treinamento de aprendizagem supervisionada foram utilizados dados históricos de empresas do segmento moveleiro, dólar americano e consumo de energia elétrica do estado do Rio Grande do Sul, combinados com dados de indicadores econômicos como PIB, SELIC, TR, entre outros para que o algoritmo possa encontrar um padrão de relacionamento na base de dados e prever a demanda com maior acurácia. O modelo da previsão do dólar resultou em um menor erro mape em relação as demais previsões, sendo o erro obtido de 1,06%. Este baixo erro deu-se também pela base de dados maior, fazendo com que a rede se adaptasse com maior eficácia ao histórico e indicadores utilizados. A previsão do consumo de energia elétrica obteve um erro mape de 2,15% e para o banco de dados menor que é a previsão de consumo de chapas de MDF da fábrica moveleira resultou em um erro de 3,85%.

Palavras-chaves: Previsão de Demanda. Redes Neurais Artificiais. Organizações. Inteligência Artificial. Aprendizado de Máquina.

ABSTRACT

Demand forecasting is an important tool for any job market sector, which companies manage and plan its organization based on the future prediction of their variables involved. Therefore, demand forecasting has a variety of ways and methods to obtain a prediction. For that reason, the present work has the aim of developing a demand prediction algorithm adaptable to the data of the organizations, being able to model and assign process variables that directly influence the prediction. Thereby, the prediction model was based on machine learning, developed with Artificial Neural Network (ANN) and, for its supervised learning training, were used historical data of companies in the furniture segment, US dollar and electric energy consumption in the state of Rio Grande do Sul, in which economic indicators such as PIB, SELIC, TR, among others are used, so that the algorithm can find a relationship pattern in the database and predict demand with accuracy. The dollar forecast model resulted in a smaller map error in relation to the other forecasts, with the obtained error of 1.06%. This low error was also due to the larger database, making the network adapt more effectively to the history and indicators used. The forecast of electricity consumption obtained a map error of 2.15% and for the smaller database which is the forecast of consumption of MDF sheets of the furniture factory resulted in an error of 3.85%.

Key Words: Artificial Neural Networks. Demand Forecasting. Organizations. Artificial Intelligence. Machine Learning.

LISTA DE FIGURAS

Figura 1: Crescimento de redes neurais para previsão de demanda.....	17
Figura 2: Os 15 autores com 2 ou 3 artigos publicados – 2000 a 2019.....	20
Figura 3: As 10 universidades com 3 ou 4 artigos publicados – 2000 a 2019.....	20
Figura 4: Os 15 países com 5 ou no máximo 30 artigos publicados – 2000 a 2019.....	21
Figura 5: Características da demanda.....	27
Figura 6: Neurônio biológico.....	33
Figura 7: Neurônio artificial.....	34
Figura 8: Arquitetura <i>feedforward</i> de camada simples.....	37
Figura 9: Arquitetura <i>feedforward</i> de camadas múltiplas.....	37
Figura 10: Arquitetura recorrente ou realimentada.....	38
Figura 11: Duas fases do treinamento da rede PMC.....	41
Figura 12: Quantidade de dados x desempenho.....	43
Figura 13: Rede neural recorrente.....	44
Figura 14: Célula LSTM: detalhes internos.....	45
Figura 15: Variação do consumo de energia e PIB.....	47
Figura 16: Fluxograma do método implementado.....	49
Figura 17: Base para previsão.....	52
Figura 18: Rede neural implementada.....	54
Figura 19: Fluxograma do código fonte.....	55
Figura 20: Previsão do dólar americano.....	56
Figura 21: Previsão do consumo de energia elétrica da região sul do Brasil.....	57
Figura 22: Previsão de consumo de MDF de fábrica moveleira.....	58

LISTA DE QUADROS

Quadro 1: Os cinco artigos mais citados no período de 2000 a 2019.....	21
Quadro 2: Características dos métodos.....	26
Quadro 3: Medidas de acurácia.....	29
Quadro 4: Aplicações da inteligência artificial.....	31
Quadro 5: Funções de ativação.....	35
Quadro 6: Aspectos comparativos entre o neurônio artificial e biológico.....	35
Quadro 7: Modelo de redes neurais.....	40
Quadro 8: Índices econômicos.....	46
Quadro 9: Indicadores utilizados nas previsões.....	50
Quadro 10: Correlação dos indicadores com cada variável de previsão.....	51
Quadro 11: Erros das previsões.....	58

LISTA DE TABELAS

Tabela 1: Pesquisa no periódico da CAPES	16
Tabela 2: Número total de publicações, na área de engenharia e de artigos na Engenharia	18
Tabela 3: Distribuição das publicações por ano	19

LISTA DE SIGLAS E ABREVIATURAS

APE	<i>Absolute Percentual Error</i>
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
ERA	<i>Relative Absolute Error</i>
GMRAE	<i>Geometric Mean Relativ</i>
IA	Inteligência Artificial
LSTM	<i>Long Short Term Memory</i>
MAE	<i>MeanAbsolute Error</i>
MAPE	<i>Mean Absolute Percentual Error</i>
MdAPE	<i>Median Absolute Percentual Error e Absolute Error</i>
MdRAE	<i>Median Relative Absolute Error</i>
MDF	<i>Medium Density Fiberboard</i>
ME	<i>Mean Error</i>
MPE	<i>Mean Percentual Error</i>
MSE	<i>Mean Square Error</i>
PCP	Planejamento e Controle da Produção
PCP	<i>Perceptron</i> de Multicamadas
RNA's	Redes Neurais Artificiais

LISTA DE SÍMBOLOS

$\%$	percentual
\bar{a}	média da amostra
σ_a	desvio padrão amostral

SUMÁRIO

1	INTRODUÇÃO	13
1.1	CONTEXTUALIZAÇÃO	14
1.2	JUSTIFICATIVA.....	16
1.2.1	Justificativa teórica	16
1.2.2	Justificativa prática	22
1.3	QUESTÃO DE PESQUISA.....	23
1.4	OBJETIVO GERAL	23
1.4.1	Objetivos específicos	23
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	PREVISÃO DE DEMANDA.....	25
2.2	MODELOS DE PREVISÃO DE DEMANDA.....	26
2.2.1	Métodos Qualitativos	27
2.2.2	Métodos quantitativos	28
2.2.2.1	Método de Análise de Séries Temporais.....	28
2.2.2.2	Métodos Causais	28
2.2.3	Erros de Previsão	29
2.2.4	Coefficiente de correlação de Pearson.....	30
2.2.5	Inteligência artificial	31
2.2.6	Redes neurais artificiais	32
2.2.6.1	Neurônio biológico.....	32
2.2.6.2	Neurônio artificial	33
2.2.6.3	Arquiteturas de redes neurais artificiais	36
2.2.6.4	Processos de treinamento de rede neural artificial	38
2.2.6.5	Rede <i>perceptron</i> multicamadas	39
2.2.6.6	Aprendizagem profunda de redes neurais artificiais	42
2.2.6.7	Redes Neurais Recorrentes.....	43
2.2.6.8	Memórias de longo-curto prazo	44
3	MÉTODO.....	46
3.1	AQUISIÇÃO E ANÁLISE DOS DADOS.....	49
3.2	DESENVOLVIMENTO DO ALGORITMO.....	51
4	RESULTADOS.....	56
4.1	PREVISÃO DO DÓLAR AMERICANO.....	56
4.2	PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA	57

4.3	PREVISÃO DE DEMANDA PARA FÁBRICA MOVELEIRA	57
5	CONCLUSÕES	59
6	TRABALHOS FUTUROS	61
	REFEÊNCIAS	62

1 INTRODUÇÃO

As organizações através de seus administradores podem fazer previsões mensais, semestrais ou até mesmo anuais, onde esta previsão pode afetar diretamente os setores da empresa, como, por exemplo, o setor de compras a partir de uma previsão do volume de compra de matéria-prima. Sendo uma previsão otimista, este volume de compra será maior, entretanto se a predição não for eficaz, faz com que a organização fique com um estoque de material, consequentemente valores monetários acumulados além da necessidade em estoque (LAS CASAS, 2012).

Segundo Las Casas (2012), a predição de demanda deve ser realizada com cautela, devido ao fato da influência expressiva nos setores fabris, conseguindo podendo afetar recursos humanos e financeiros da organização. Entretanto, a previsão pode ser feita através de métodos científicos e não científicos. Os métodos científicos são baseados em estudos e ferramentas de previsão de demanda, para os qual necessita-se de conhecimento específico e, em alguns casos não apresentam uma predição eficaz. Contudo, os métodos não científicos buscam o conhecimento dos gestores e gerencia para determinar uma demanda aproximada para a empresa, se baseando apenas por conhecimento de mercado e produto.

Alguns métodos são utilizados para a previsão de demanda de forma sistemática e científica, seguindo um modelo desenvolvido para tal. Os modelos mais usados na previsão de demanda são a média móvel simples e ponderada, modelo de suavização exponencial e modelos de regressão (MORETTIN e TOLOI, 2006). Os modelos de previsão mais conhecidos baseados na extrapolação são os modelos ARIMA (modelo auto regressivo, integrado de média móvel), proposto por Box e Jenkins (1976) e também citado por Souza e Camargo (2004). Existem outros métodos de previsão tais como os modelos estruturais clássicos de Harvey, modelos bayesianos de Harrison, com sua utilização podendo ser mais eficaz dependendo do tipo de dados das organizações (SPIRO, RICH e STANTON, 2010).

Em paralelo aos métodos tradicionais de previsão de demanda, a inteligência artificial vem tomando espaço para solucionar o problema de dados não lineares, onde através de um treinamento supervisionado tais técnicas aprendem com os dados históricos da empresa podendo prever a demanda futura. Entretanto, a inteligência artificial também é capaz de modelar variáveis que influenciam na demanda da empresa, como indicadores econômicos ou financeiros, tornando-a adaptável aos dados e variáveis organizacionais (MORETTIN e TOLOI, 2006).

1.1 CONTEXTUALIZAÇÃO

A previsão de demanda é uma ferramenta de gestão, onde sua utilização faz parte do planejamento estratégico das organizações. Para se adaptar ao mercado devido a variações econômicas constantes, as empresas possuem a necessidade de uma predição de qualidade para que se mantenham competitivas, adequando-se à informação predita, como material, pessoas e processos, de forma a compreender a demanda de seus produtos (CAVALHEIRO, 2003).

O estudo de Reis e seus colaboradores (2015) apresenta simulações de previsão de demanda ancoradas apenas com dados históricos de vendas de baterias de uma empresa varejista, a qual utiliza os métodos de média móvel simples, ponderada e com suavização exponencial, e os métodos de regressão linear e ajuste sazonal, com o emprego destas técnicas, foi obtido dessa forma uma predição com baixa acurácia, devido aos dados modelados através dos métodos serem somente o histórico de vendas, da maneira que serve apenas para seu estudo com a empresa em questão. Entretanto, o estudo foi utilizado para o planejamento e gestão da organização de forma a obter uma base para a mesma.

Werner (2004) desenvolveu uma análise de combinação de previsão de demanda, ajustada, com a opinião de especialistas da área. Analisou de forma separada dados históricos e econômicos, onde previu a demanda com cada grupo de dados. Entretanto, para a união destas análises o autor utilizou combinação de técnicas quantitativas e qualitativas (opinião de especialistas) para encontrar a previsão final.

A previsão de demanda pode ser aplicada em diversas áreas. Perini e Bertolde (2016) aplicaram modelos de predição para o setor de petróleo. O trabalho seguiu a mesma linha que Reis et al. (2015), utilizando média móvel, média exponencial móvel, equação linear para a tendência, ajustamento exponencial para a tendência, sazonalidade simples e sazonalidade com tendência. O objetivo era encontrar um modelo que melhor se adaptasse à sua necessidade, mensurando sua eficácia com os parâmetros do erro acumulado e o Desvio Médio Absoluto (MAP), no qual conclui que os modelos que melhor se adequam são a Média Exponencial Móvel e o Ajustamento Exponencial para a Tendência (PERINI e BERTOLDE, 2016).

Perini e Bertolde (2016) também ressaltam que cada método de previsão possui suas particularidades, sendo necessário o domínio de suas características e conhecimento dos dados históricos que serão analisados para se obter uma previsão satisfatória, ou seja, que fique próxima do real.

Percebe-se que os modelos de previsão clássicos de demanda, possuem características pouco adaptativas, obtendo-se resultados bons ou ruins em conformidade com o formato dos

dados coletados, sendo também limitada a inserção de variáveis que influenciam a demanda das organizações (HAIR et al., 2010).

Além dos métodos citados, como método de previsão de demanda, podem-se utilizar redes neurais artificiais (RNA's), as quais passam por uma etapa de treinamento baseando-se nos bancos de dados, aprendendo o comportamento das séries e aplicando o mesmo viés para uma predição. As redes neurais artificiais, em análise de séries temporais, possuem, também, a capacidade de flexibilidade para previsões iterativas, as quais conseguem lidar com a não-linearidade das séries temporais, possibilitando uma predição paramétrica e não-paramétrica (PASCHOALINO et al., 2007).

Paschoalino et al. (2007) analisaram a aplicação de redes neurais artificiais, técnica que está dentro do contexto da inteligência artificial, na previsão de demanda de energia elétrica no Brasil. Seu principal objetivo foi medir a performance da RNA frente ao comportamento não-linear e não-sazonal das séries históricas de consumo de energia elétrica entre os anos de 1982 a 2003, para a qual, utilizou-se o ano de 2001 para validação dos resultados, devido ao uso racional da energia elétrica neste ano. Entretanto, o ano de 2003 que não fez parte do treinamento serviu como referência para testar a generalização da rede neural e validar os resultados, onde o autor ressalta a obtenção de um erro médio quadrático na faixa de 0,02%.

As redes neurais artificiais aplicadas à previsão de demanda, além de conseguir se adaptar a dados não-lineares, podem ser flexíveis e adaptáveis a variadas séries históricas e até mesmo séries híbridas, podendo estas redes, ser facilmente implementadas na indústria em geral, podendo-se modelar em conformidade com a base de dados (PASCHOALINO et al., 2007).

Em Campos (2008), o autor analisa o uso de Rede Neuro-Fuzzy e Redes Neurais Artificiais, com a qual faz a previsão, também, de energia elétrica para curto, médio e longo prazo, onde seu desempenho é medido por indicadores. A Rede Neuro-Fuzzy se mostrou, segundo o autor, um melhor comportamento na previsão em médio prazo. Entretanto, a Rede Neural Artificial respondeu com maior eficácia na predição em curto prazo, no caso um ano (CAMPOS, 2008).

Para um modelo de predição adaptável aos variados cenários das indústrias, ou seja, aos diferentes comportamentos de demanda, a inteligência artificial, através do método das Redes Neurais Artificiais, é uma ferramenta que pode dar a qualquer setor industrial ou comercial uma previsão com maior grau de precisão, e o principal, adaptável ao meio, de forma que a própria ferramenta aprende com a base de dados, na qual possui a facilidade de atribuir novas variáveis que influenciam no processo de forma rápida e eficaz, bem como captam as

mudanças que podem ocorrer numa série temporal influenciadas por flutuações da demanda (KOURENTZES, 2013).

Diferente de Werner (2004), a proposta do presente trabalho é utilizar os dados históricos e econômicos como entrada da Rede Neural Artificial, deixando-a criar uma forma que os dados convirjam para uma demanda, mas ressaltando que os dados econômicos serão avaliados por correlação com os dados históricos de demanda das organizações.

1.2 JUSTIFICATIVA

As ferramentas de previsão de demanda e estudos realizados são poucos adaptáveis aos dados de bases que as empresas possuem, limitando-se, em geral, somente ao histórico passado, onde outras variáveis que influenciam na demanda da organização não são atribuídas para uma predição com maior acurácia.

1.2.1 Justificativa teórica

Considerando a importância da previsão da demanda, foi realizada uma pesquisa bibliométrica, com um corte temporal entre o período de 2000 a 2019.

No período do ano de 2000 até primeiro de abril de 2019, segundo consulta ao porta de periódicos da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), 1815 publicações estavam relacionadas diretamente com previsão de demanda, tendo sido selecionado o campo assunto para a pesquisa. Destas publicações, em aproximadamente 163, os autores utilizaram Redes Neurais Artificiais para predição de demanda e 1652 utilizaram outros métodos para previsão, conforme ilustra a Tabela 1.

Tabela 1: Pesquisa no periódico da CAPES


Termo pesquisado no título do artigo	Quantidade de artigos
<i>“Demand Forecasting”</i>	1.652
<i>“Demand Forecasting and Neural Networks”</i>	163
Total	1.815

Fonte: CAPES (2019).

A previsão de demanda através da inteligência artificial cresce anualmente, pois, nos últimos anos, as publicações de periódicos no portal da CAPES crescem de forma destacada como ilustra a

Figura 1. Este fato é devido ao avanço e aprofundamento nos estudos sobre redes neurais, não só em previsão de demanda, mas também em todas as áreas da tecnologia e software.

Figura 1: Crescimento de redes neurais para previsão de demanda



Fonte: CAPES (2019).

Na maioria dos artigos estudados, utilizam-se métodos convencionais da engenharia de produção para previsão de demanda, como média exponencial móvel, ajustamento exponencial para a tendência, média móvel, equação linear para a tendência, sazonalidade simples e sazonalidade com tendência. A utilização de Redes Neurais Artificiais para a resolução do problema é variada, na qual muitos artigos visam à validação da qualidade de predição da inteligência artificial.

Da mesma forma, a pesquisa realizada na base de dados *Scopus*, que constitui a maior base de citações e resumos de literatura revisada por pares (ELSEVIER, 2018), mostrou uma interconexão significativa entre os termos pesquisados. A busca pelo termo “*demand forecasting*” resultou em 3.839 resultados, buscando-se a partir de título, resumo e palavras-chave. Estes resultados, quando filtrados pela área de engenharia e por tipo de documento (artigo), resultaram em 879 artigos sobre o assunto.

O primeiro artigo publicado em 1969 foi “*Long range demand forecasting for the electric utility industry*”, dos autores Stanton, Gupta e El-Abiad, tendo recebido até abril de 2019, 8 citações.

A busca combinada pelos termos “*neural networks*” resultou em 335.334 documentos, buscando-se a partir de título, resumo e palavras-chave. Estes resultados, quando filtrados pela área de Engenharia e por tipo de documento (artigo), resultaram em 67.571 artigos sobre o assunto.

O primeiro artigo publicado em 1962 foi “*Analog Computer Simulation of a Neural Element*”, do autor Hiltz, tendo recebido até abril de 2019, 16 citações.

E busca combinada pelos termos “*Demand Forecasting*” e “*neural networks*” resultou em 612 trabalhos, buscando-se a partir de título, resumo e palavras-chave. Estes resultados, quando filtrados pela área de engenharia, resultaram em 282 documentos e por tipo de documento (artigo), resultaram em 142 artigos sobre o assunto.

Os dois primeiros artigos publicados foram em novembro de 1995, “*Power-demand forecasting using a neural network with an adaptive learning algorithm*”, dos autores Dash; Liew e Ramakrishna, com 22 citações até abril de 2019, e o trabalho “*Demand Forecasting using Fuzzy Neural Computation, with Special Emphasis on Weekend and Public Holiday Forecasting*”, dos autores Srinivasan, Chang e Liew, com 104 citações também até abril de 2019.

Na Tabela 2, apresenta-se o número total de publicações em todas as áreas, especificamente na área de Engenharia que é objeto deste estudo e o número de artigos publicados no período de 2000 a abril de 2019.

Tabela 2: Número total de publicações, na área de engenharia e de artigos na Engenharia

	Total de Publicações	Área de Engenharia	Artigos na Engenharia
“ <i>Demand Forecasting</i> ”	3.839	1.936	879
“ <i>Neural Networks</i> ”	335.334	142.599	67.571
“ <i>Demand Forecasting</i> ” e “ <i>Neural Networks</i> ”	612	282	142

Fonte: Elaborada pelo autor (2019).

Observa-se, pelos dados apresentados na Tabela 2, que do total de publicações sobre previsão de demanda, 50,43% são da área da Engenharia e que destes, 45,40% são artigos. Quanto às publicações sobre redes neurais, 42,52% são da área da Engenharia e 47,85% são artigos. Quando procurado na base de dados *Scopus* os termos previsão de demanda e redes neurais, obteve-se 46,08% na área da Engenharia e destes, 23,20% são artigos.

Analisando-se as publicações dos termos “*Demand Forecasting*” e “*Neural Networks*” em conjunto, como pode-se observar, os dois primeiros trabalhos foram publicados em 1995. Fazendo um corte transversal para a análise no período de 2000 a 2019. A Tabela 3, mostra o comportamento das publicações no período de 2000 a abril de 2019, onde observam os aumentos, os decréscimos ou manutenção da quantidade de publicações no período analisado. Em 2018, foi o ano que apresentou maior número de publicações, 18 publicações, ou seja, 12,68%. Esta análise torna-se importante neste contexto pois mostra a tendência das publicações no tema “*Demand Forecasting*” e “*Neural Networks*”.


Tabela 3: Distribuição das publicações por ano

Ano	Número de publicações	%
2000	2	1,41
2001	2	1,41
2002	0	0,00
2003	1	0,70
2004	1	0,70
2005	7	4,93
2006	1	0,70
2007	2	1,41
2008	6	4,23
2009	11	7,75
2010	8	5,63
2011	12	8,45
2012	6	4,23
2013	11	7,75
2014	14	9,86
2015	6	4,23
2016	9	6,34
2017	18	12,68
2018	16	11,27
2019	9	6,34
Total	142	100,00

Fonte: Elaborado com base na Scopus (2019).

Na Figura 2, apresenta-se os 15 autores que no período de 2000 a 2019 tiveram dois ou três artigos publicados.

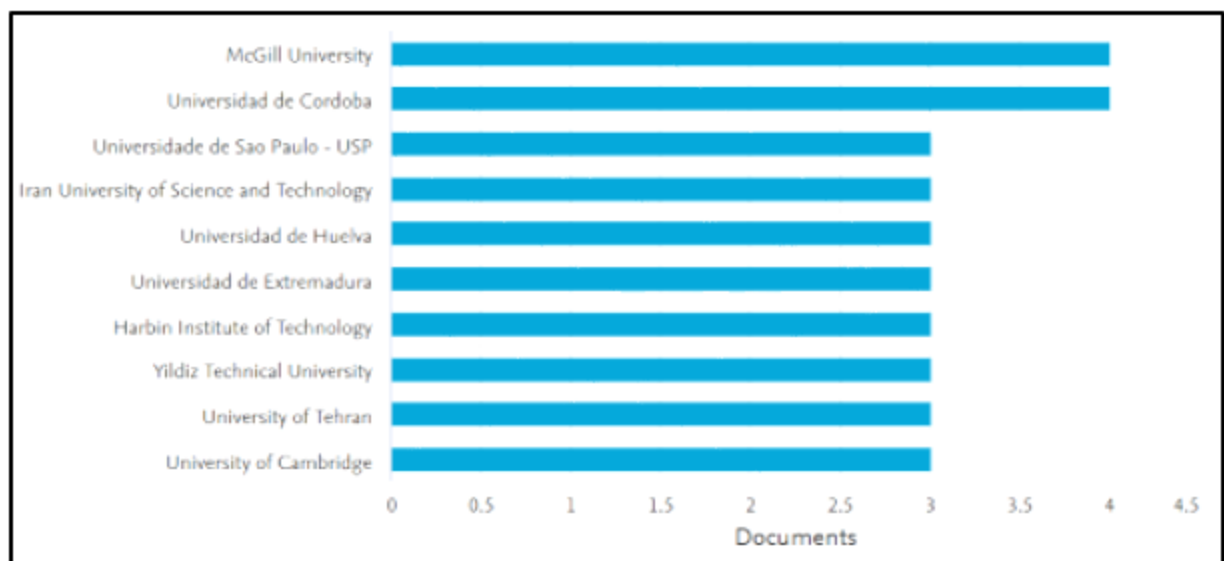
Figura 2: Os 15 autores com dois ou três artigos publicados – 2000 a 2019



Fonte: Elaborado com base na Scopus, 2019.

Na Figura 3, destacam-se as dez instituições de ensino que tiveram três ou quatro artigos publicados no período de 2000 a 2019 publicados.


Figura 3: As dez Universidades com três ou quatro artigos publicados – 2000 a 2019



Fonte: Elaborado pelo autor com base na Scopus (2019).

Na Figura 4, mostram-se os 15 países que tiveram cinco ou mais artigos publicados no período de 2000 a 2019 publicados. O máximo observado foi 30 para a China.

Figura 4: Os 15 países com cinco ou no máximo 30 artigos publicados – 2000 a 2019



Fonte: Elaborado pelo autor com base na Scopus (2019).

O Brasil aparece no 8º lugar, representando 3,52% do total de publicações sobre previsão de demanda e redes neurais. Destes, três documentos foram publicados pela Universidade de São Paulo, um pela Universidade Federal de Santa Catarina e um pela Faculdade Santa Rita de Cássia, São Paulo.

sobre “Demand Forecasting” e “Neural Networks”.

Quadro 1 mostra os quatro artigos mais citados sobre “Demand Forecasting” e “Neural Networks”.

Quadro 1: Os quatro artigos mais citados no período de 2000 a 2019 continua

Título do Artigo	Autores	Ano	Periódico	Citações
<i>Short-term water demand forecast modelling at IIT Kanpur using artificial neural networks</i>	Jain, A., Varshney, A.K., Joshi, U.C.	2001	<i>Water Resources Management</i>	289

<i>Monthly electric energy demand forecasting based on trend extraction</i>	Romera, E. G.; Moran, M.A.J.; Fernandez D. C.	2006	<i>IEEE Transactions on Power Systems</i>	185
<i>Artificial neural networks as applied to long-term demand forecasting</i>	Al-Saba, T., El-Amin, I.	1999	<i>Artificial Intelligence in Engineering</i>	180
<i>Urban water demand forecasting with a dynamic artificial neural network model</i>	Ghiassi, G., Zimbra, D.K., Saidane, H.	2008	<i>Journal of Water Resources Planning and Management</i>	169

Fonte: Elaborado pelo autor com base na Scopus (2019).

Assim, o presente trabalho possui o foco de uma Rede Neural Artificial adaptável à base de dados das empresas, na qual pode se utilizar multivariáveis para a predição da demanda, tornando-a mais consistente. Desta forma, a realização do trabalho justifica-se, em termos teóricos, pois tratará de uma melhoria à teoria já existente e publicada acerca do assunto.

1.2.2 Justificativa prática

Diferenciando-se da teoria, na qual visa também à medição do erro de previsão da demanda através da Rede Neural Artificial, a prática propõe um algoritmo adaptável aos dados das empresas, onde se possa trabalhar com múltiplas variáveis no processo de predição, as quais possuem influência sobre a demanda da organização, que é considerada a variável de saída.

A predição da demanda nas empresas, muitas vezes, é baseada em apenas dados históricos passados, onde a acurácia desta previsão, muitas vezes, apresenta um erro inaceitável. Também são utilizados métodos convencionais da engenharia de produção, como a média móvel, regressão linear e análise de regressão, mas nestes casos a dificuldade aumenta quando a organização possui múltiplas variáveis que influenciam na demanda da organização.

No setor elétrico, a previsão de demanda é realizada em curto, médio e longo prazo. Um erro, principalmente na predição a longo, prazo pode comprometer sérios danos à economia de um país, onde sua matriz energética principal é a energia elétrica, devido ao fato que qualquer tomada de decisão não fará efeito a curto prazo, pois questões de infraestrutura e geração são

projetos lentos e complexos. Este é um caso que no qual uma predição de demanda precisa pode otimizar o projeto, minimizar os custos e servir de tomada de decisão aos gestores da área.

Outro caso prático é no setor moveleiro, onde a empresa estoca matéria-prima para a produção de móveis. Uma previsão de demanda realizada com precisão auxiliará a diretoria em negociação de compra de material, material humano para trabalho, redução de estoque, redução de custos, enfim, é realizada a gestão e programação baseando-se nos dados de predição.

Na previsão de demanda baseando-se por inteligência artificial, a gestão pode atribuir variáveis não lineares, como o conhecimento de especialistas da área, indicadores econômicos, entre outros. Esta possibilidade deixará a predição mais customizada conforme a empresa necessitar.

Portanto, o presente trabalho visa a fácil adaptação e aplicação na previsão de demanda através de inteligência artificial, onde a própria Rede Neural desenvolvida possui a capacidade de aprender, de forma supervisionada, baseando-se em dados históricos e variáveis processuais, na qual entregará como saída a predição de demanda com erros aceitáveis pelas organizações.

1.3 QUESTÃO DE PESQUISA

Como fazer a previsão da demanda em empresas ou organizações utilizando dados históricos e atribuir variáveis não lineares no processo de predição?

1.4 OBJETIVO GERAL

O objetivo do trabalho é desenvolver um algoritmo baseado em Redes Neurais Artificiais para previsão de demanda de empresa e organizações.

O algoritmo terá a flexibilidade de se adaptar aos dados numéricos das empresas, sendo eles modelados pelos gestores, para o qual os mesmos poderão atribuir variáveis não-lineares no processo de predição.

1.4.1 Objetivos específicos

A partir do objetivo geral, derivam-se os seguintes objetivos específicos como sendo:

- a) desenvolver uma Rede Neural Artificial de múltiplas camadas;
- b) desenvolver um algoritmo na linguagem de programação Python;

- c) analisar os dados históricos da demanda, restringindo-se ao consumo de energia elétrica do estado do Rio Grande do Sul, de uma fábrica moveleira localizada na Serra Gaúcha, e o valor do dólar comercial americano;
- d) correlacionar os indicadores que influenciam na demanda através de ferramentas estatísticas;
- e) validar o modelo utilizando uma parte do banco de dados construído.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, fundamenta-se a base teórica, ou seja, descreve-se os métodos que serão utilizados na previsão de demanda, focando-se principalmente no campo de inteligência artificial, ou seja, Redes Neurais Artificiais para a previsão da demanda.

2.1 PREVISÃO DE DEMANDA

Para fins de planejamento, uma ferramenta fundamental é a previsão da demanda, que auxilia na determinação dos recursos básicos das organizações. Uma previsão acertada permite diminuir o estoque, reduzir o tempo de resposta com o cliente, planejar os recursos humanos, entre outros. Os métodos de previsão de demanda podem ser baseados em modelos matemáticos utilizando dados históricos, métodos qualitativos vindos da experiência dos gestores ou a combinação de ambos (RITZMAN e KRAJEWSKI, 2004).

A previsão de demanda é utilizada para dar suporte à tomada de decisões por meio de análises quantitativas, ou seja, refere-se essencialmente ao comportamento da demanda do mercado futuramente, isto é, o quanto a força de compra ocorrerá no mercado (REIS et. al, 2015).

As empresas precisam ter o conhecimento do objeto que se deseja fazer a previsão de demanda. Esta demanda pode ser realizada de forma global ou com itens comercializados pela organização, fazendo a nível regional ou global dependendo do objetivo da proposta e seu tempo de predição com prazo curto, médio ou longo (KOTLER, 1998).

O período para uma previsão de demanda eficaz possuem muita relação com a parte comportamental dos clientes ou até mesmo da sociedade. A previsão realizada para períodos longos tornam-se dependentes de muitos fatores comportamentais e econômicos, podendo sofrer variações entre a previsão e a real demanda, fazendo levar um plano diretor a uma direção errada. Já as previsões de curto prazo possuem uma precisão maior, pois são menos influenciadas por variáveis econômicas e comportamentais, na qual estas variáveis não possuem uma variação imediata (TUBINO, 2009).

Os setores de marketing e vendas são os principais responsáveis pela previsão de demanda, mas o setor de Processo e Controle da Produção (PCP) está interessado diretamente na qualidade de predição, pois sua acurácia irá influenciar diretamente no desempenho das funções de planejamento e controle do sistema produtivo. Contudo, em algumas empresas de pequeno e médio porte a previsão acaba ficando a encargo do próprio PCP (TUBINO, 2000).

2.2 MODELOS DE PREVISÃO DE DEMANDA

Segundo Davis, Aquilano e Chase (2001) as diversas técnicas de previsão de demanda podem ser classificadas em três categorias gerais, que são:

- a) qualitativas;
- b) análise de séries temporais;
- c) modelos causais.

As técnicas qualitativas são empregadas, na maioria dos casos, quando não existem dados, baseando-se em estimativas e opiniões de especialistas. Entretanto, a análise de séries temporais, a qual pertence ao grupo de métodos quantitativos, possui o conceito que existindo a demanda do passado pode ser estimada a demanda futura. É utilizada principalmente para previsões de curto prazo, útil para programação de trabalhadores.

No entanto, a técnica de modelo causais, que pertence, também, ao grupo de métodos quantitativos, demonstra a relação entre a demanda e fatores fundamentais ou do ambiente no qual ocorrem relações de causa-e-efeito. Os modelos causais são empregados, em sua essência, para previsões a longo prazo, nas quais a gestão pode tomar providências para direcionar a visão da empresa em um limite temporal extenso (DAVIS, AQUILANO e CHASE, 2001).

Os autores descrevem as características de cada método, tanto quantitativos como qualitativos, relacionando horizonte de tempo, complexidade do modelo, precisão do modelo e os dados necessários, como ilustra o Quadro 2, podendo analisar qual método é útil à determinada previsão.

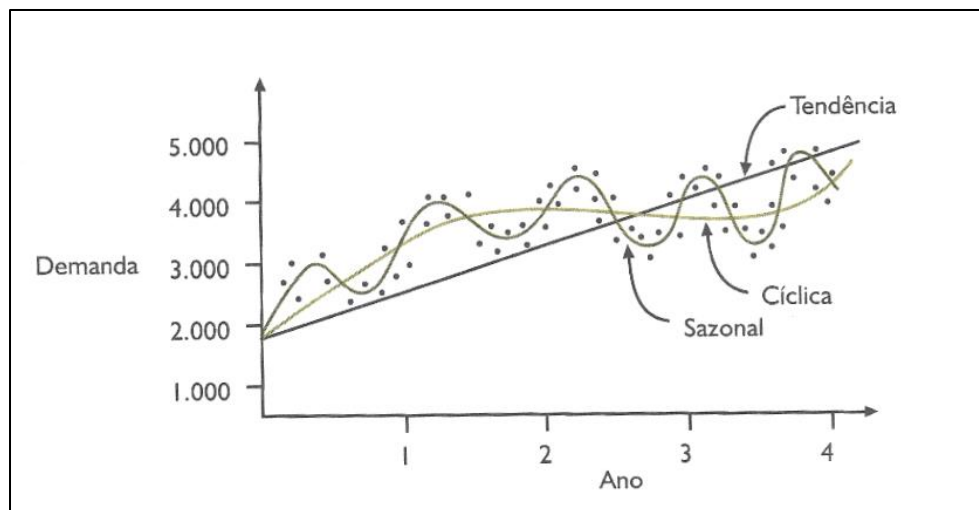
Quadro 2: Características dos métodos

Técnica	Horizonte de tempo	Complexidade do Modelo	Precisão do Modelo	Dados Necessários
I. Qualitativo				
Método Delphi	Longo	Alta	variável	muitos
II. Séries Temporais				
Média Móvel	Curto	muito baixa	média	poucos
Média ponderada exponencial	Curto	Baixa	adequada	muito poucos
Regressão Linear	Longo	média alta	média alta	muitos
III. Causal				
Análise de Regressão	Longo	adequada	alta	muitos

Fonte: Adaptado de Davis, Aquilano e Chase (2001).

A demanda das organizações pode ser cíclica, sazonal, com tendência ou até mesmo com tendência e sazonal. A característica sazonal é quando a demanda varia conforme algum período, dependendo de outras variáveis que envolvem o processo. A característica cíclica é repetição da demanda em cada período estudado. Por fim, a demanda com tendência é onde os dados possuem uma acréscimo ou decréscimo ao longo do tempo, como pode ser visto na Figura 5 (DAVIS, AQUILANO e CHASE, 2001).

Figura 5: Características da demanda



Fonte: Davis, Aquilano e Chase (2001).

2.2.1 Métodos Qualitativos

Davis, Aquilano e Chase (2001) descrevem que no segmento da teoria qualitativa existe três métodos: Método Delphi, Pesquisa de Mercado e Analogia Histórica.

O Método Delphi requer um grupo de especialistas que respondem um questionário, diante de um mediador que reúne os resultados e forma um novo questionário para o mesmo grupo de especialistas. Este método iterativo é usado para previsões de longo prazo onde, também, não existem dados.

Outro método é a Pesquisa de Mercado, como seu nome já relata, demonstra o levantamento de dados, podendo ser realizados de várias maneiras, entrevistas, levantamentos, entre outros, na qual se testa hipóteses sobre o mercado.

Por fim, os autores descrevem sobre o método de Analogia Histórica, que relaciona a previsão de demanda com um produto similar existente, na qual o produto observado seja uma derivação do produto similar.

2.2.2 Métodos quantitativos

Os métodos quantitativos se baseiam na construção de modelos estocásticos com base em informações históricas e podem ser divididos em séries temporais e causais ou explicativos (HONAISSER e SAUAIA, 2008).

2.2.2.1 Método de Análise de Séries Temporais

Na teoria de Análise de Séries Temporais, encontram-se os métodos de Média Móvel, Média Ponderada Exponencial, Análise de Regressão e Projeção de Tendência (DAVIS, AQUILANO e CHASE, 2001).

Segundo os autores a Média Móvel Simples é realizada de forma que cada dado pontual tenha o mesmo peso, ou seja, sua média é calculada dividindo-se a soma dos valores pontuais pelo número total de pontos.

Por sua vez, a Média Ponderada Exponencial diferencia-se da média simples, pelo fato que o responsável pela previsão pode atribuir pesos diferentes para cada dado pontual, fazendo com que dados recentes tenham maior peso na previsão (DAVIS, AQUILANO e CHASE, 2001)

Segundo Moreira (1993) a Média Ponderada Exponencial pode apresentar mais duas variações, a Média Ponderada Exponencial de Primeira Ordem e a Média Ponderada Exponencial de Segunda Ordem, onde sua previsão pode ser mais longa com uma suavização relativa à sua ordem.

O método de Análise de Regressão relaciona os dados com o tempo, utilizando técnicas de ajuste, na maioria dos casos, como os mínimos quadrados, diferenciando-se da análise de regressão dos métodos Causais no quesito múltiplas variáveis que o último apresenta (DAVIS, AQUILANO e CHASE, 2001).

2.2.2.2 Métodos Causais

Nos métodos Causais Davis, Aquilano e Chase (2001) afirmam que no modelo de Análise de Regressão, pode ser utilizada a entrada de múltiplas variáveis no modelo proposto. Muitas vezes o processo de previsão de demanda é afetado por diversos fatores que influenciam a precisão da previsão, então, com o uso do método de Análise de Regressão com múltiplas

variáveis é possível obter um modelo de previsão com maior acurácia, devido a esta flexibilização de variáveis.

2.2.3 Erros de Previsão

Para Corrêa e Corrêa (2004) é importante acompanhar dois erros de previsão: a “amplitude” ou “tamanho” do erro e o chamado “viés” dos erros. A amplitude ou tamanho, como seu nome expressa, envolve o tamanho do erro. Por exemplo, a previsão foi de dez mil peças do produto “X” vendidas em determinado período enquanto na realidade somente cinco mil peças foram realmente vendidas, a diferença representa a amplitude do erro.

No entanto, o autor retrata o viés como um superdimensionamento ou subdimensionamento sistemático da previsão de demanda. Isso ocorre devido à exclusão de alguma variável que influencia no processo, na qual identifica-se e realiza-se a correção do problema que estava causando o viés.

Segundo Ritzman e Krajewski (2004), a gestão das organizações precisam quantificar o erro antes de pensar em minimizá-lo. Este erro é simplesmente a diferença obtida subtraindo a previsão da demanda com a demanda real do período avaliados.

O erro está ligado diretamente com a acurácia do modelo, quanto menor o erro maior a acurácia. Werner (2004), descreve que é proveitoso utilizar mais de um critério de comparação, pelo fato de diferentes critérios oferecerem diferentes indicações. O Quadro 3 lista as principais medidas de acurácia que podem ser aplicadas.

Quadro 3: Medidas de acurácia

Sigla	Descrição	Tradução
ME	Mean Error	Erro Médio
MAE	Mean Absolute Error	Erro Absoluto Médio
MSE	Mean Square Error	Erro Quadrático Médio
MPE	Mean Percentual Error	Erro Percentual Médio
APE	Absolute Percentual Error	Erro Percentual Absoluto
MAPE	Mean Absolute Percentual Error	Média dos Erros Percentuais Absolutos
MdAPE	Median Absolute Percentual Error	Mediana dos Erros Percentuais Absolutos
ERA	Relative Absolute Error	Erro Absoluto Relativo
GMRAE	Geometric Mean Relative Absolute Error	Média Geométrica dos Erros Absolutos Relativos
MdRAE	Median Relative Absolute Error	Mediana dos Erros Absolutos Relativos
RMSE	Root Mean Square Error	Raiz do Erro Quadrático Médio

Fonte: Adaptado de Werner (2004).

Nesta dissertação foram utilizados para avaliar o erro de previsão o Erro Percentual Médio Absoluto (MAPE) e a Raiz do Erro Quadrático Médio (RMSE), cuja as expressões são apresentadas pelas equações (1) e (2), respectivamente.

$$MAPE(h) = \left[\frac{1}{NP \sum_{t=1}^{NP} \left| \frac{e_t(h)}{Y_{t+h}} \right|} \right] \times 100 \quad (1)$$

$$RMSE(h) = \left[\frac{1}{NP \sum_{t=1}^{NP} e_t^2(h)} \right]^{\frac{1}{2}} \quad (2)$$

Onde:

NP= número de períodos previstos;

$e_t(\ell)$ = erro de previsão, Y são os dados, t passos-à-frente representado por

$$e_t(h) = Y_{t+h} - \hat{Y}_t(h).$$

2.2.4 Coeficiente de correlação de Pearson

As pesquisas empíricas, frequentemente, possuem propósito de associação entre variáveis, onde a sua existência direciona a análise, evidenciação e conclusões de achados de pesquisadores (MARTINS, 2001).

O coeficiente de Correlação de Pearson é uma medida quantitativa da relação entre duas variáveis numéricas. Este coeficiente, denominado como “r”, pode variar de -1 à +1, ou também, ser expresso em porcentagem. Na prática, se $r > 0,7$ ou $r < -0,7$ indica uma forte correlação entre as variáveis (MALHOTRA, 2011; TRIOLA, 2008).

Segundo Martins (2001), a correlação entre duas variáveis numéricas é puramente matemática, ou seja, são isentas de implicação de causa e efeito entre ambas, pois as mesmas podem ser influenciadas por outras variáveis de maneira que de origem possuam uma forte correlação.

2.2.5 Inteligência artificial

A Inteligência Artificial (IA) é um ramo da ciência da computação, oficialmente criada em 1956 na conferência de Dartmouth, realizada na Universidade de Dartmouth nos Estados Unidos da América (EUA), a partir de ideias filosóficas, científicas e tecnológicas herdadas de outras ciências. (BITTENCOURT, 2006)

No encontro de Dartmouth, os conferencistas chegaram à conclusão, que, para uma máquina ser inteligente teria de ser capaz de produzir raciocínio complexo, usando modelos internos do mundo, busca de soluções possíveis, o planejamento e o raciocínio para resolver problemas, representação simbólica da informação, sistema de organização hierárquico e execução sequencial de programa (MATARIC, 2014).

Conforme Silva, Spatti e Flauzino (2016), mesmo que os primeiros trabalhos sobre IA tenham sido publicados há mais de cinquenta anos, os estudos se intensificaram nos anos de 1990, tendo nos dias atuais um enorme potencial, onde o Quadro 4 descreve algumas aplicações.

Quadro 4: Aplicações da inteligência artificial

1	Avaliação de imagens captadas por satélites
2	Classificação de padrões de escrita e fala
3	Reconhecimento de faces em visão computacional
4	Controle de trens de grande velocidade
5	Previsões de ações no mercado financeiro
6	Identificações de anomalias em imagens médicas
7	Identificação automática de perfis de crédito para clientes de instituições financeiras
8	Controle de aparelhos eletrônicos e eletrodomésticos

Fonte: Silva, Spatti e Flauzino (2016).

A Inteligência Artificial cada vez mais ganha ênfase no mundo tecnológico, pois está presente nos projetos mais complexos. As redes sociais, com seu reconhecimento facial é um exemplo da aplicação da IA, conseguindo realizar tal tarefa com a precisão de um ser humano (SILVA, 2018).

2.2.6 Redes neurais artificiais

As Redes Neurais Artificiais são modelos computacionais baseados nos neurônios biológicos, possuindo a capacidade de aquisição e manutenção do conhecimento, podendo ser definidas como um conjunto de unidades de processamento, chamadas por neurônios artificiais. Os neurônios artificiais fazem um número grande de interconexões, chamadas de sinapses artificiais, caracterizadas por pesos sinápticos (HAYKIN, 2009).

O autor descreve que as características mais relevantes das RNA são:

- a) adaptação por experiência;
- b) capacidade de aprendizado;
- c) habilidade de generalização;
- d) organização de dados;
- e) tolerância a falhas;
- f) armazenamento distribuído;
- g) facilidade de implementação.


Ainda, as RNAs possuem várias áreas de aplicações, uma delas descrita por Haykin (2009), são os sistemas de previsão, como previsão de séries temporais, previsão de mercado financeiro, previsões climáticas, entre outras, com o objetivo de estimar valores futuros levando em consideração medidas observadas em seu domínio.

2.2.6.1 Neurônio biológico

Os processadores biológicos, conhecidos como conjuntos de neurônios, são responsáveis pelo processamento no cérebro humano, objetivando-se das funcionalidades vitais e operações como pensar e memorizar (SILVA, SPATTI e FLAUZINO, 2016).

No sistema nervoso cerebral, o neurônio através de estímulos elétricos causados de reações físico-químicas, transmite impulsos sob determinadas condições de operação. Este elemento biológico pode ser dividido em três principais partes: dendritos, corpo celular e axônio, como ilustra a Figura 6.

Figura 6: Neurônio biológico



Fonte: Silva, Spatti e Flauzino (2016).

Os dendritos do neurônio biológico possuem a função de captar, de forma contínua, estímulos vindos de outros neurônios. O corpo celular, também conhecido como somador, é o responsável por processar as informações advindas dos dendritos a fim de produzir um potencial de ativação se o neurônio poderá disparar um impulso elétrico ao longo do axônio. Por sua vez o axônio possui a finalidade de transmitir os impulsos elétricos para outros neurônios conectores ou para aqueles que se conectam diretamente com o tecido muscular (LUGER, 2004).

O autor descreve que os neurônios biológicos, atuando conjuntamente formando a rede neural biológica, é responsável por todo processamento e gerenciamento do corpo humano. Estima-se que o cérebro possui mais de cem bilhões de neurônios, interligando-se por conexões sinápticas a mais outros seis mil neurônios em média, portanto, pode chegar a seiscentos trilhões de sinapses.


2.2.6.2 Neurônio artificial

A partir da arquitetura do sistema nervoso e cérebro humano foi desenvolvida as Redes Neurais Artificiais. O neurônio artificial é a unidade processadora básica, um modelo simplificado do neurônio biológico (HAYKIN, 2001).

Segundo o autor, os neurônios artificiais presentes nas Redes Neurais são não-lineares. Eles exercem funções simples, como coletar dados em suas entradas, gerar uma saída conforme sua função operacional, levando em consideração sua função de ativação.

A Figura 7 ilustra a unidade básica de processamento, o neurônio artificial, podendo conter inúmeras entradas de sinais e realizando paralelismo entre os mesmos.

Figura 7: Neurônio artificial



Fonte: Silva, Spatti e Flauzino (2016).

- a) x_1, x_2, \dots, x_n : Sinais de entrada
- b) w_1, w_2, \dots, w_n : Pesos sinápticos
- c) Σ : Combinador linear
- d) θ : Limiar de ativação
- e) u : Potencial de ativação
- f) g : Função de ativação
- g) y : Sinal de saída.

Os sinais de entrada são valores medidos do meio externo, representando as variáveis de aplicação específica. Os pesos sinápticos realizam a função de ponderação, que irá impor alteração conforme o aprendizado da Rede Neural Artificial.

No entanto, o combinador linear faz a agregação dos sinais de entrada com seus devidos pesos sinápticos com o objetivo de produzir um valor que, em conjunto com limiar de ativação, possa gerar um valor de disparo em direção à saída do neurônio.

Para Lima (2014), o potencial de ativação geralmente é a diferença do valor entre o combinador linear e o limiar de ativação. A função de ativação, por sua vez, é limitar a saída do neurônio dentro de um intervalo de valores de interesse, podendo ser regrada, conforme a aplicação, por inúmeras funções, como mostra-se no Quadro 5.

Quadro 5: Funções de ativação

<i>Nome</i>	<i>Função</i>	<i>Domínio</i>
Limiar	$F(v) = \begin{cases} v \geq 0 \Rightarrow 1 \\ v < 0 \Rightarrow 0 \end{cases}$	[0 , 1]
Linear	$F(v) = v$] - ∞ , +∞ [
Sigmóide	$F(v) = \frac{1}{1 + \exp(-av)}$	[0 , 1]
Gaussiana	$F(v) = e^{\left(\frac{-x^2}{2}\right)}$	[0 , 1]
Tangente Hiperbólica	$F(v) = \frac{e^v - e^{-v}}{e^v + e^{-v}}$	[-1 , 1]

Fonte: Lima (2014).

As Redes Neurais Artificiais possuem similaridade funcional com o cérebro humano. O Quadro 6 compara algumas características dos neurônios artificiais e biológicos (SILVA, SPATTI e FLAUZINO, 2016).

Quadro 6: Aspectos comparativos entre o neurônio artificial e biológico

Parâmetros	Neurônio Artificial	Neurônio Biológico
Eficiência energética (Operação/Segundos)	$10^{-6} J$	$10^{-16} J$
Tempo de processamento (Operação/Neurônio)	$10^{-9} s$	$10^{-3} s$
Mecanismo de processamento	Tipicamente sequencial	Tipicamente paralelo

Fonte: Silva, Spatti e Flauzino (2016).

Observa-se que o tempo de processamento do neurônio biológico é muito maior comparado ao neurônio artificial, mas devido ao processamento cerebral possuir alto grau de paralelismo, faz com que a rede neural biológica seja mais rápida.

2.2.6.3 Arquiteturas de redes neurais artificiais

Segundo a obra de Silva, Spatti e Flauzino (2016), a arquitetura de uma Rede Neural Artificial descreve como os neurônios artificiais estão dispostos um em relação ao outro, ligados diretamente por conexões sinápticas.

A topologia de uma RNA pode assumir diferentes formas de composições estruturais, de forma que uma arquitetura pode ter duas topologias. Por exemplo, uma delas pode ser constituída de neurônios com função de ativação lógica e a outra topologia com neurônios com função de ativação hiperbólica, flexibilizando para atender a necessidade do problema (SILVA, SPATTI e FLAUZINO, 2016).

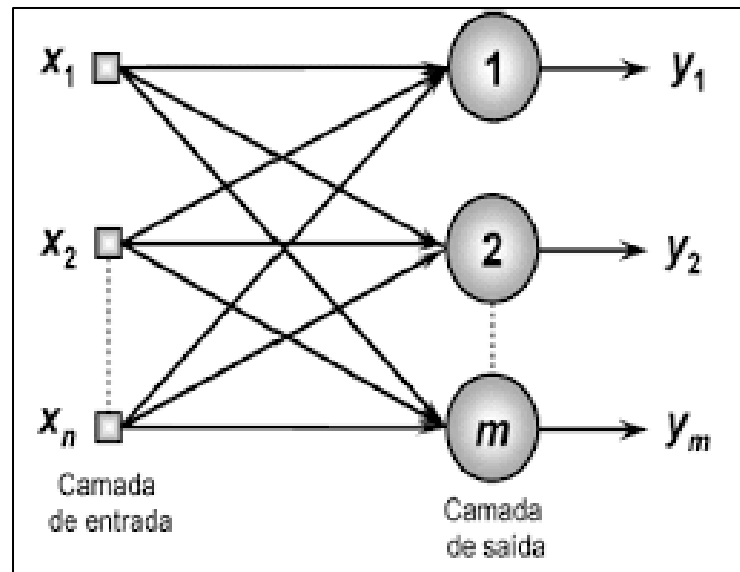
Uma Rede Neural Artificial, basicamente, pode ser dividida em três partes, a camada de entrada, camada oculta e camada de saída. A camada de entrada possui a função de recebimento da informação, normalmente normalizadas em relação às faixas de variação dinâmica, implicando em uma melhor precisão numérica para a Rede Neural. As camadas ocultas, possuem a responsabilidade de extrair as características associadas ao processo, recebendo dados, ou seja, informações da camada anterior. Por último, tem-se a camada de saída responsável pela apresentação dos resultados finais advindos do processamento de camadas anteriores a esta (SILVA, SPATTI e FLAUZINO, 2016).

Segundo os autores, as arquiteturas de Redes Neurais Artificiais considerando interligação e disposição dos neurônios, e ainda a constituição de suas camadas, podem ser divididas em:

- a) Redes *Feedforward* (alimentação para frente) de camada simples;
- b) Redes *Feedforward* de camadas múltiplas;
- c) Redes recorrentes;
- d) Redes reticuladas.

A arquitetura *Feedforward* de camada simples é uma rede composta apenas pela camada de entrada, uma única camada de neurônios e a camada de saída, onde todas entradas são interligadas com todos neurônios presentes na camada da arquitetura, seguindo a informação unidirecionalmente, da entrada para a saída, coincidindo-se que a quantidade de saídas é a mesma que a quantidade de neurônios, como ilustra a Figura 8.


Figura 8: Arquitetura *Feedforward* de camada simples



Fonte: Silva, Spatti e Flauzino (2016).

No entanto, a arquitetura *Feedforward* de camadas múltiplas, ilustrada pela Figura 9, é constituída por várias camadas ocultas/escondidas de neurônios, sendo empregada em inúmeros problemas como classificação de padrões, identificação de sistemas, previsões, entre outros. O número de camadas ocultas em uma rede multicamadas é relacionada, geralmente, com a complexidade do problema, sendo na maioria das vezes a quantidade de entradas e saídas diferentes do número de neurônios das camadas ocultas (SILVA, SPATTI e FLAUZINO, 2016).

Figura 9: Arquitetura *feedforward* de camadas múltiplas

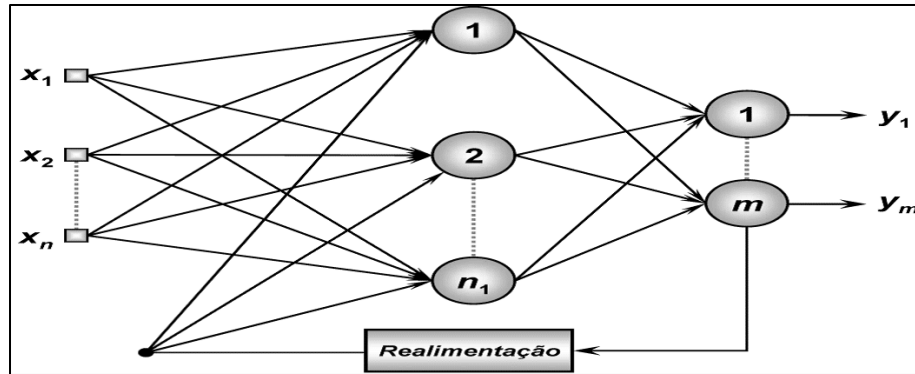


Fonte: Silva, Spatti e Flauzino (2016).

Os autores descrevem, que a arquitetura recorrente ou realimentada, mostrada na Figura 10, são redes que utilizam as saídas como informação de entrada, por meio de

realimentação, qualificando-as para processos dinâmicos de informações, ou seja, sistemas variantes temporalmente como previsão de séries temporais, otimização, controle de processos, entre outros.

Figura 10: Arquitetura recorrente ou realimentada



Fonte: Silva, Spatti e Flauzino (2016).

2.2.6.4 Processos de treinamento de rede neural artificial

O princípio de aprendizagem de um sistema nervoso complexo foi proposto por Hebb em 1949, onde descreve que este sistema complexo pode ser reduzido a processos locais em que os erros detectáveis alterariam a intensidade das conexões sinápticas (KOVÁCS, 1996).

As Redes Neurais Artificiais possuem a capacidade de aprendizado a partir de amostras. Após passarem pelo processo de aprendizagem relacionando as entradas com suas saídas, são capazes de generalizar as soluções produzindo resultados próximos daquele esperado, partindo de qualquer sinal inserido em sua entrada (SILVA, SPATTI e FLAUZINO, 2016).

Este processo de treinamento de uma Rede Neural consiste em uma sequência de passos ordenados, chamados também de algoritmo de aprendizagem. O processo realiza a adequação dos pesos sinápticos a Rede Neural, objetivando-se generalizar as possíveis saídas mapeadas em sua arquitetura, onde cada ajuste de pesos sinápticos será denominado como uma época de treinamento.

Segundo Silva, Spatti e Flauzino (2016), existem vários tipos de treinamento, alguns são listados a seguir:

- a) treinamento supervisionado;
- b) treinamento não-supervisionado;
- c) treinamento com reforço;

- d) aprendizagem usando lotes de padrões (off-line);
- e) aprendizagem usando padrão-por-padrão (on-line).

As duas principais técnicas de treinamento, segundo os autores, são o treinamento supervisionado e o não-supervisionado.

O treinamento supervisionado, consiste em mapear a entrada em sua respectiva saída desejada, isto é, direcionar os sinais das amostras para seu resultado na saída do neurônio, havendo a necessidade da tabela de atributos/valores demonstrando o comportamento dos dados, a qual a partir destas informações a Rede Neural formulará um caminho para generalizar todos os resultados.

Nesta modalidade de treinamento, com a aplicação da tabela de atributos/valores, o algoritmo de aprendizagem atualiza os pesos sinápticos e limiares em cada época de aprendizagem comparando a saída da Rede Neural Artificial com a saída real do sistema proposto, corrigindo-os a cada iteração até ser alcançado um erro aceitável pelo programador.

No treinamento não-supervisionado inexistem as respectivas saídas desejadas, portanto, a Rede Neural irá se ajustar, ou seja, se auto-organizar, analisando a relação existente entre os elementos do conjunto total das amostras, identificando similaridades e realizando os ajustes nos pesos sinápticos e limiares dos neurônios, refletindo internamente na Rede Neural (SILVA, SPATTI e FLAUZINO, 2016).

Algo similar à aprendizagem não-supervisionado é a ciência realizada por seres humanos. Os cientistas/pesquisadores propõem hipóteses para explicar observações, realizam suas avaliações usando critérios e testam via experimento. Portanto, a Rede Neural Artificial de aprendizado não-supervisionado possui o mesmo intuito análogo aos pesquisadores (LUGER, 2004).

2.2.6.5 Rede *perceptron* multicamadas

Vários pesquisadores contribuíram ao longo da história das Redes Neurais Artificiais. Mcculloch e Pitts, em 1943, introduziram a ideia de Redes Neurais como ferramenta computacional. Outro nobre pesquisador que contribuiu foi Hebb que desenvolveu a primeira regra de aprendizagem auto-organizada no ano de 1949. Não menos importante, tem-se o pesquisador Rosenblatt, em 1958, que propôs a rede *Perceptron* como a primeira rede de aprendizagem supervisionada (HAYKIN, 2001).

Segundo Silva, Spatti e Flauzino (2016), o modelo de rede *Perceptron* pode ser de camada única ou multicamadas. Além deste modelo, os autores apresentam em sua obra inúmeras outras redes, listadas no Quadro 7.

Quadro 7: Modelo de redes neurais

1	Rede <i>Perceptron</i>
2	Rede <i>Adalaine</i>
3	Rede <i>Perceptron</i> multicamadas
4	Redes de função de base radial
5	Redes recorrentes de Hopfield
6	Redes auto-organizáveis de Kohonen
7	Redes ART (<i>Adaptive resonance theory</i>)
8	Redes LVQ (<i>Learning vector quantization</i>)

Fonte: Silva, Spatti e Flauzino (2016).

As características das redes *Perceptron* de multicamadas (PMC) é a existência de duas ou mais camadas de neurônios, ou seja, ao menos uma camada de neurônio oculta, situada entre a camada de entrada e a camada de saída (SILVA, SPATTI e FLAUZINO, 2016).

As redes de topologia *Perceptron* de múltiplas camadas, segundo os autores, possuem uma vasta aplicabilidade em diversos tipos de problemas e em variadas áreas do conhecimento como, por exemplo, aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais, otimização de sistemas, entre outras.


A rede PMC possui a arquitetura *feedforward* de multicamadas, cujo treinamento é supervisionado, sendo a saída de cada camada oculta a entrada da próxima camada pertencente à Rede Neural, propagando então o sinal entre os níveis.

A quantidade de camadas intermediárias de uma rede *Perceptron* pode aumentar ou diminuir conforme a classe do problema a ser tratado, disposição espacial das amostras de treinamento e até mesmo os valores sinápticos dos pesos podem influenciar a definição da topologia.

O processo de treinamento realizado nas redes PMC é utilizado com o algoritmo *back-propagation*, também conhecido como regra Delta generalizada. A Figura 11 ilustra uma Rede Neural com duas camadas escondidas, representando as duas fases de treinamento do algoritmo

back-propagation que é denominado *forward* (propagação adiante) e *backward* (propagação reversa).

Figura 11: Duas fases do treinamento da rede PMC



Fonte: Silva, Spatti e Flauzino (2016).

A fase *forward*, a partir das entradas (X_1, X_2, X_n) das amostras, propaga camada por camada até gerar a respectiva saída, durante a qual os pesos sinápticos e limiares permanecerão inalterados nesta fase do treinamento. Com o resultado produzido pelas saídas, é realizado o cálculo de erro por meio de comparação com a saída desejada, pois se trata de um aprendizado supervisionado. Com a medida do erro, é aplicada a segunda parte do processo *back-propagation*, chamada de *backward*, realizando a tarefa de correção dos pesos sinápticos e limiares dos neurônios de todas as camadas. Estas duas fases fazem a atualização automática dos pesos, convertendo as saídas da rede para o resultado desejado (SILVA, SPATTI e FLAUZINO, 2016).

Haykin (2001), em sua obra, intitula o algoritmo de aprendizagem da rede *Perceptron* multicamadas como retropropagação e observa que pode ser um algoritmo lento para convergência dos pesos sinápticos, salientando a possibilidade de utilização de heurísticas para a inicialização dos pesos.

Silva, Spatti e Flauzino (2016), descrevem uma sequência de passos do algoritmo de *back-propagation* como mostra a seguir:

1. obter o conjunto de amostras de treinamento;
2. associar o vetor de saída desejada para cada amostra;
3. iniciar os pesos sinápticos aleatórios pequenos;
4. especificar taxa de aprendizagem e precisão requerida;
5. iniciar o contador de número de época;
6. repetir as instruções;

- a. aplica a fase *forward* do algoritmo *back-prapagation* e incrementa-se o contador de época;
- b. comparar as saídas conforme condições de parada;
- c. se for satisfatório, encerrar a aprendizagem;
- d. se não for satisfatório, aplicar a fase de *backward* do algoritmo de *back-prapagation* e repetir as instruções contidas no item 6.

Com a rede treinada, aplica-se os pesos sinápticos na fase de operação da rede *Perceptron* com as novas amostras que se deseja obter resultados. Os autores ressaltam que os passos de *forward* e *backward* somente são possíveis na fase de treinamento não efetuando nenhum tipo de ajuste na operação da rede.

2.2.6.6 Aprendizagem profunda de redes neurais artificiais

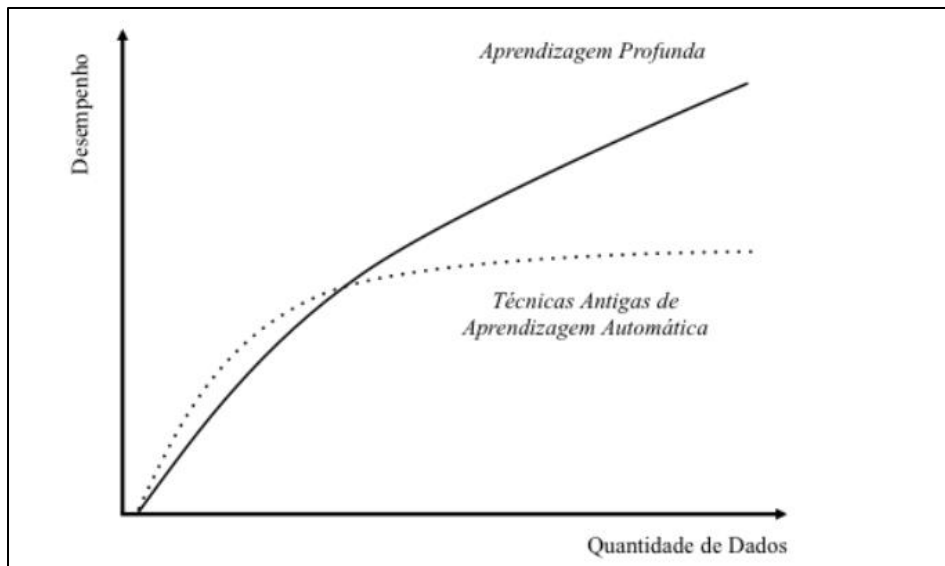
A Redes Neurais de aprendizagem profunda, usualmente conhecida do termo em inglês *Deep Learning*, teve início ao seu conceito na década de 80 com o objetivo de melhorar a eficiência dos algoritmos desenvolvidos na época (RODRIGUES, 2018).

Segundo Rodrigues (2008), as Redes Neurais de aprendizagem profunda possuem ótimos resultados no reconhecimento de voz, navegação de veículos, filtros de redes sociais, tradução automática de textos, previsão de dados futuros, entre outras aplicações.

O *Deep Learning* consegue estabelecer um método de aprendizagem para diferentes camadas da rede, conseqüentemente cada camada pode aprender isoladamente, fazendo com que a solução apresente uma adaptação mais complexa dos dados de treinamento gerando um melhor resultado.

O método de aprendizagem profunda possui a tendência de melhorar o desempenho conforme aumenta a quantidade de amostras de treinamento, ou seja, com bases de dados menores as Redes Neurais Convencionais tendem a serem mais eficientes, mas à medida que esta base aumenta, o aprendizado profundo se sobressai, conforme ilustra a Figura 12 (RODRIGUES, 2018).

Figura 12: Quantidade de dados x desempenho



Fonte: Rodrigues (2018).


O autor descreve a importância do pré-processamento das amostras, relatando ser um dos principais fatores de redes não realizarem o aprendizado adequado. Esta filtragem está relacionada a eliminação de redundâncias nas quais os dados possuem o mesmo significado e retirada de *outliers*, ou seja, dados que não condizem com a realidade da amostra. Faz necessário o uso da normalização dos dados para que os mesmos fiquem na mesma grandeza e agilize o processamento do algoritmo.

Nos treinamentos de Redes Neurais profundas, podem acontecer dois fenômenos, o *overfitting* e *underfitting*. O *overfitting* é quando o algoritmo se adapta demais às amostras de treinamento, portanto quando apresentada uma base diferente, terá erros de classificação ou interpretação. Por outro lado, *underfitting* é baixa adaptação aos dados da base de treinamento, portanto ao apresentar entradas diferentes seu erro será maior (RODRIGUES, 2018).

2.2.6.7 Redes Neurais Recorrentes

As Redes Neurais Recorrentes, usualmente utilizadas para previsões, tratamento de imagens e arquiteturas complexas, se diferem das Redes Neurais *feed-forward* na questão que suas camadas possuem ligações com camadas anteriores formando memórias de curto prazo, como ilustra a Figura 13. Entretanto, a informação da Rede Neural Recorrente possui um único sentido de propagação, de forma que as saídas dependerão das entradas anteriores, criando assim o efeito de recorrência (NELSON, 2017).

Figura 13: Rede Neural Recorrente



Fonte: Nelson (2017).

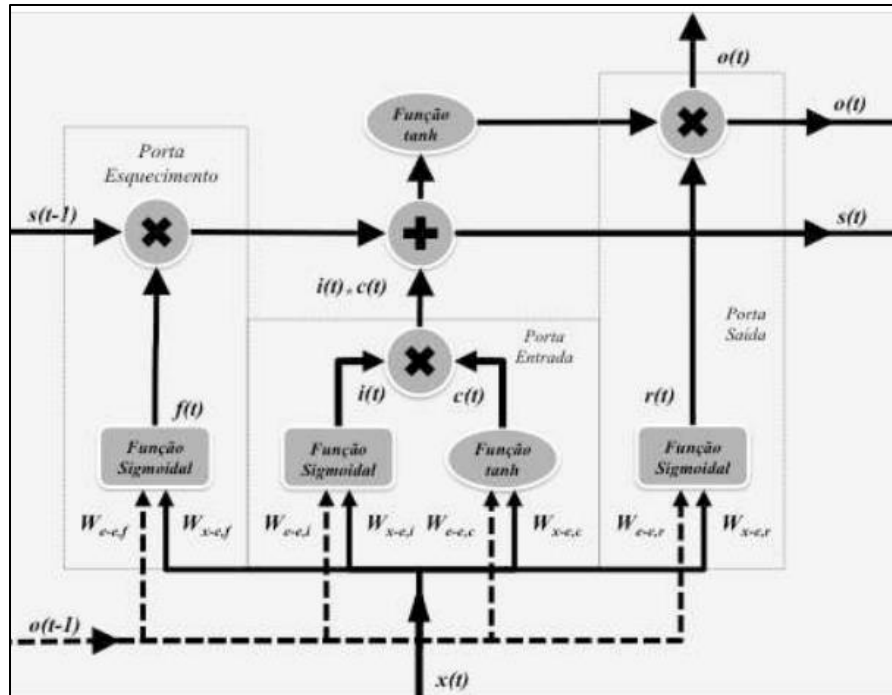
As Redes Neurais Recorrentes incorporam, parte ou totalmente, um Perceptron de múltiplas camadas, utilizando a capacidade de mapeamento não-linear do mesmo, se tornando um modelo auto-regressivo, que possui a capacidade de memória devido a sua realimentação (HAYKIN, 2001).

2.2.6.8 Memórias de longo-curto prazo

Do termo em inglês *Long Short Term Memory* (LSTM), as Memórias de Longo-Curto Prazo utilizam a retenção de informações anteriores, introduzindo o conceito de células de memória no interior dos neurônios das camadas escondidas, a qual resolve o problema das chamadas explosão-zeramento que faz com que a Rede Neural convencional torne seus valores nulos. Durante a fase de treinamento as LSTM, lentamente, conseguem criar um campo de memória de longo prazo devido a seus parâmetros adaptáveis, modificando e inserindo seus pesos nos neurônios conforme aprende com os dados das amostras, da mesma forma acontece para a memória de curto prazo (RODRIGUES, 2018).

Rodrigues (2018) utiliza o conceito de portões nas redes LSTM. O primeiro é o portão do esquecimento, no qual o neurônio decide se o dado é relevante para mantê-lo. O segundo portão é o de entrada, que é responsável para adicionar uma nova informação na memória da célula e, por último, o portão de saída, no qual passa a informação adiante, sendo que a Figura 14 ilustra este conceito de portas e sua arquitetura.

Figura 14: Célula LSTM: detalhes internos



Fonte: Rodrigues (2018).

O efeito de memória de curto ou longo prazo é inserida de forma supervisionada na Rede Neural Artificial, na qual o conjunto de informações de treinamento é processado e armazenado parcialmente ou totalmente em forma de pesos sinápticos ligando um neurônio a outro em suas camadas (HAYKIN, 2001).

Portanto, para o presente trabalho será realizado o desenvolvimento da Rede Neural Artificial baseado nas Redes Recorrentes do tipo LSTM. Haykin (2001) e Rodrigo (2018) afirmam que as Redes Recorrentes são as mais indicadas para séries temporais, principalmente quando se trabalha com *Bigdate*.

3 MÉTODO

Este capítulo apresenta o método utilizado no trabalho de pesquisa com Redes Neurais Artificiais para previsão de séries temporais, na forma sintetizada para elaboração da previsão da demanda em organizações.

Para tomar como referência os resultados de erro MAPE, serão considerados satisfatório sendo eles mais baixos que 8%, conforme Srinivasan, Chang e Liew, (1995) descreveram.

Com a base bibliográfica analisada, coletou-se os dados de demanda históricas das seguintes variáveis:

- a. variação do Dólar Americano;
- b. consumo de matéria-prima (MDF- *Medium Density Fiberboard*) para uma empresa moveleira localizada na serra gaúcha;
- c. consumo de energia elétrica da região sul do Brasil.

Com base em correlação e intuito de fazer com que a Rede Neural aprendesse com qualquer indicador, alguns dos indicadores econômicos foram utilizados no trabalho conforme pode-se observar no Quadro 8.

Quadro 8: Índices econômicos

Sigla	Descrição
Bovespa	Bovespa
SELIC	Sistema Especial de Liquidação e Custódia
EFMEC	Emprego formal -Material elétrico e de comunicação
IEF	Índice do Emprego Formal
Cesta Básica	Cesta Básica
TR	Taxa Referencial
INCC	Índice Nacional de Custo da Construção
PIB	Produto Interno Bruto

Fonte: Elaborado pelo autor (2019).

A correlação de Pearson foi calculada para todos os pares de variáveis, buscando encontrar as relações entre os indicadores econômicos. Ela serviu de entrada para a Rede Neural a ser desenvolvida.


A opinião de especialistas da área pode ser atribuída como uma variável do processo, contudo se for de medida qualitativa se torna necessário quantificá-la, podendo utilizá-la como dado de entrada para a Rede Neural Artificial criada. Devem ser eliminados da amostra dados caracterizados como valores atípicos, conhecidos na estatística como *outliers* (HAIR et al, 2010).

A análise gráfica e estatística do histórico de demanda, indicadores econômicos e outras variáveis pertinentes ao processo das organizações foi realizada através de planilhas eletrônicas.

A observação gráfica dos resultados estatísticos dos indicadores financeiro e outros dados é primordial para o seguimento do estudo, pois direcionou o foco da pesquisa, conseqüentemente mostrou ou descartou caminhos que podem ser tomados, como a normalização dos dados e definição da quantidade de camadas de neurônios para a Rede Neural Artificial.

O consumo de energia indica o desenvolvimento econômico de um país. Tais dados, normalmente, possuem uma tendência de correlacionar-se com indicadores econômicos, um deles é o PIB como descreve estudo realizado pela Agência Nacional de Energia Elétrica (ANEEL) em 2008, ilustrado pela Figura 15 (ANEEL, 2008).

Figura 15: Variação do consumo de energia e PIB



Fonte: (ANEEL, 2008).

Portanto, com base na afirmação do estudo da ANEEL, encontrou-se uma forte correlação (termo utilizado pela estatística para indicar que dados estão correlacionados entre si) entre os indicadores econômicos e os dados históricos das organizações.

Ainda, ao término da análise dos dados e variáveis utilizadas em cada processo de previsão, foi realizada a normalização dos mesmos, com o objetivo de minimizar os problemas entre variáveis distintas, agilizando, também, o uso da Rede Neural Artificial para determinada proposta, conforme cita Silva, Spatti e Flauzino (2016). A normalização seguirá a Equação número (3).

$$y = \frac{a_r - \bar{a}}{\sigma_a} \quad (3)$$

onde:

y: valor normalizado

a_r : valor real

\bar{a} : média da amostra

σ_a : desvio padrão amostral

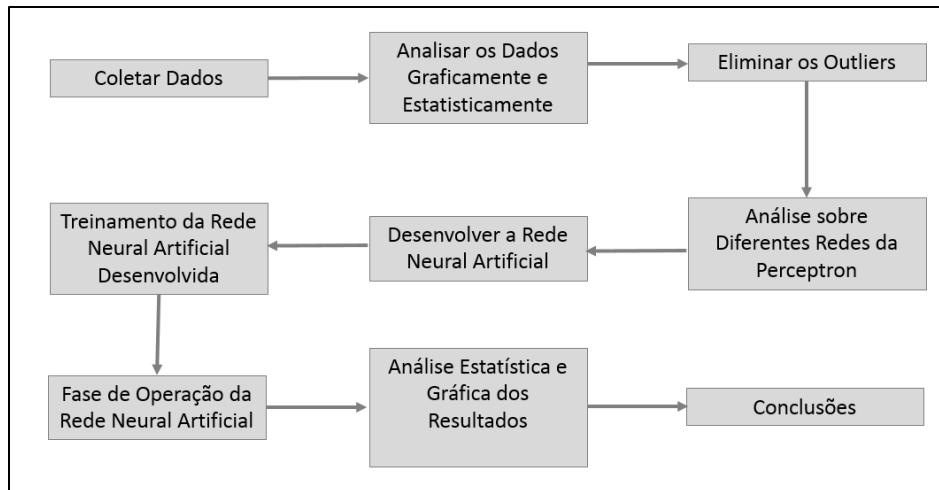
Através da análise de correlação dos dados históricos e os indicadores econômicos envolvidos, desenvolveu-se a rede neural de topologia *LSTM*, conforme indica Rodrigues (2018), falando que seu uso em séries temporais trazem resultados satisfatórios. A implementação foi realizada na linguagem Python. Esta linguagem de programação, segundo Silva (2018) é de alto nível, ou seja, seus comandos são mais próximos à linguagem humana. Por se tratar de um *software* livre, sua implementação foi facilitada em função da bibliografia sobre tal linguagem.

O desenvolvimento da Rede Neural Artificial foi realizado através do *software Spyder*, uma distribuição da Anaconda, que é um compilador de linguagem *Python*. Foi utilizada a biblioteca do *Keras*, a mesma utiliza parte da biblioteca do *Tensorflow*, ambas com foco em *machine learning*. Com funções específicas de treinamento e montagem de Rede Neural Artificial, com sua aplicação pode-se diminuir o código fonte e realizar o treinamento e validação dos dados em menos tempo. Essas bibliotecas possuem métodos para aplicação de função de ativação dos neurônios, métricas para medição de erros e otimizadores.

Na etapa de desenvolvimento do algoritmo da Rede Neural Artificial, foi analisado a topologia *Perceptron* de Multicamadas, no entanto seus resultados primários não foram satisfatórios devido à quantidade de dados dos problemas.

Por outro lado, a rede LSTM teve uma performance mais adaptativa aos dados, ou seja, encontrou um padrão com maior facilidade no banco de dados, o que confirma os achados na literatura, na qual autores relatam o seu bom desempenho para previsão de demanda. (RODRIGUES, 2018). O passo-a-passo do método a ser utilizado pode ser visto na Figura 16.

Figura 16: Fluxograma do método implementado



Fonte: Elaborada pelo autor (2019).

3.1 AQUISIÇÃO E ANÁLISE DOS DADOS

As séries temporais dos dados de consumo de MDF utilizada para previsão da empresa moveleira foi fornecida pela própria empresa, aplicado um fator multiplicativo, não repassado ao estudo. As demais séries históricas e dados econômicos foram extraídos da base de dados do Banco Central do Brasil (www.bcb.gov.br), estes já disponibilizados em planilha eletrônica separados por vírgulas.

Os registros históricos foram utilizados conforme disponibilidade, sendo que a base de dados do dólar foi a partir de 1995 até 2016 para treinamento e 2017 até o final de 2018 para validação. O consumo de energia elétrica a partir de 1998 até 2016 para treinamento e da mesma forma que os dados dos Dólar, forma utilizados 2017 até o final de 2018 para validação dos dados. Entretanto, a empresa moveleira por ter menor histórico, os dados a partir de 2014 até o final de 2017 utilizou-se para treinamento e o ano de 2018 para validação dos dados. Os indicadores usados também respeitam as mesmas datas declaradas nos históricos, respectivamente. O Quadro 9 descreve os indicadores atribuídos na previsão de cada organização, podendo ser ampliado conforme necessidade da mesma ou até mesmo por questões de acurácia e confiabilidade dos dados.

Quadro 9: Indicadores utilizados nas previsões

		Finalidade de Previsão		
		Dólar Americano	Consumo de Energia Elétrica na Região Sul do Brasil	Consumo de Matéria Prima de fábrica Moveleira
Indicadores	Cesta básica		X	X
	EFMEC		X	
	IEF		X	X
	PIB		X	X
	SELIC	X	X	X
	BOVESPA		X	X
	Eleição	X		
	TR	X		
	Mês	X	X	X

Fonte: Elaborado pelo autor (2019).

Nos registros previsores, foram inseridos os meses do histórico que se deseja fazer a previsão, portanto, a Rede Neural Artificial pode fazer o aprendizado identificando se existe sazonalidade na série, assimilando um determinado período sendo como um aumento ou diminuição da demanda.

Salienta-se que foi utilizado para a previsão do dólar americano o indicador que indica se foi ano eleitoral no País, deixando a rede treinar e encontrar algum possível vínculo com esta variável. O intuito do trabalho é fazer um algoritmo adaptativo a qualquer dado numérico, no entanto gestores conhecedores de cada segmento poderão atribuir indicadores que são utilizados para mensurar algo na empresa, tornando-os uma variável no processo de predição. O mesmo pode ser feito com seu conhecimento de mercado, podendo trazer resultados melhores.

Como citado por Martins (2001), o fator de correlação de Pearson é apenas matemático, o fator não indica que os dois dados analisados tenham uma dependência entre si. Foram utilizados índices com correlação maior que 0,4 ou menor que -0,4 para as previsões, mas nada impede de se utilizar índices que não apresentem correlação, pois a Rede Neural Artificial pode assimilar vários índices e criar uma relação entre todos. A correlação de Pearson

de cada indicador respectivamente com seu histórico a ser previsto foi analisada através de planilha eletrônica, podendo-se ser visto o resultado no Quadro 10.

Quadro 10: Correlação dos indicadores com cada variável de previsão

		Finalidade de Previsão		
		Dólar Americano	Consumo de Energia Elétrica na Região Sul do Brasil	Consumo de Matéria Prima de fábrica Moveleira
Indicadores	Cesta básica		0,9528	0,7107
	EFMEC		0,9239	
	IEF		0,968	-0,7507
	PIB		0,965	0,8407
	SELIC	-0,4152	-0,7415	-0,849
	BOVESPA		0,8251	0,884
	TR	-0,755		

Fonte: Elaborado pelo autor (2019).

Os indicadores de previsão ficaram limitados conforme a base de dados, alguns possuíam registros mensais, mas o histórico de demanda a ser previsto era diário, não podendo ser utilizado. Portanto, salienta-se que o gestor especialista no determinado assunto, pode atribuir diversos indicadores de previsão respeitando a sua análise, podendo encontrar resultados com uma acurácia desejada. O algoritmo desenvolvido tem como objetivo ser adaptável a qualquer dado numérico lançado pelo gestor.

3.2 DESENVOLVIMENTO DO ALGORITMO

Para a predição da demanda futura, utilizou-se um número de dados do passado, sendo eles vários indicadores financeiros e o próprio histórico de demanda. Então, foi definida a utilização de uma variável no código fonte para determinar o número de dados do passado que poderiam ser usados para as previsões futuras, podendo ser atualizado conforme a base de dados da organização. Caso seja necessário 20 registros anteriores, o algoritmo irá filtrar os dados

chamados previsores em uma matriz e fará o apontamento para o resultado esperado, que será o registro após o que será utilizado para a previsão.

A Figura 17 ilustra uma base de registros. A porção destacada na cor vermelha representa os dados que são utilizados para a entrada da Rede Neural Artificial, ou seja, os dados previsores, já o valor destacado em amarelo irá ser o registro de saída da Rede Neural Artificial.

Figura 17: Base para previsão

Índice	Valor Dólar	Selic	TR	Mês	Eleição
1	3.2616	0.028333	0.0936	11	0
2	3.2636	0.028333	0.0579	12	0
3	3.2506	0.028333	0.0329	12	0
4	3.2322	0.028333	0.0614	12	0
5	3.2354	0.028333	0.0939	12	0
6	3.2892	0.026481	0.1158	12	0
7	3.2811	0.026481	0.0787	12	0
8	3.2845	0.026481	0.1144	12	0
9	3.3149	0.026481	0.0597	12	0
10	3.3036	0.026481	0.0277	12	0
11	3.3332	0.026481	0.0561	12	0
12	3.3182	0.026481	0.0807	12	0
13	3.2881	0.026481	0.1113	12	0
14	3.2883	0.026481	0.1032	12	0
15	3.2909	0.026481	0.1151	12	0
16	3.3045	0.026481	0.1151	12	0
17	3.3209	0.026481	0.0847	12	0
18	3.32	0.026481	0.0481	12	0
19	3.3031	0.026481	0.076	12	0
20	3.308	0.026481	0.1075	12	0
21	3.308	0.026481	0.1441	12	0

Fonte: Elaborado pelo autor (2019).

Devido à base de dados variar de organização para organização, foi desenvolvido no algoritmo a auto-leitura conforme o tamanho das linhas do arquivo de registros, entretanto será passado para a rede a quantidade de índices previsores e o número de registros anteriores que se deseja usar para prever a demanda.

Com os dados em formato de tabela separados por vírgula em planilha eletrônica, foi criada uma função de importação da mesma para o ambiente de programação, o *Spyder*. Destes

dados, utilizou-se a função “dropna” para eliminar qualquer valor nulo entre os dados. Os dados qualitativos, como a data, foram removidos.

Conforme Rodrigues (2018) descreve a importância da normalização dos dados, a mesma foi implementada, com o cuidado de referenciar sempre a mesma base de registros, desta forma a rede irá convergir em menor tempo.

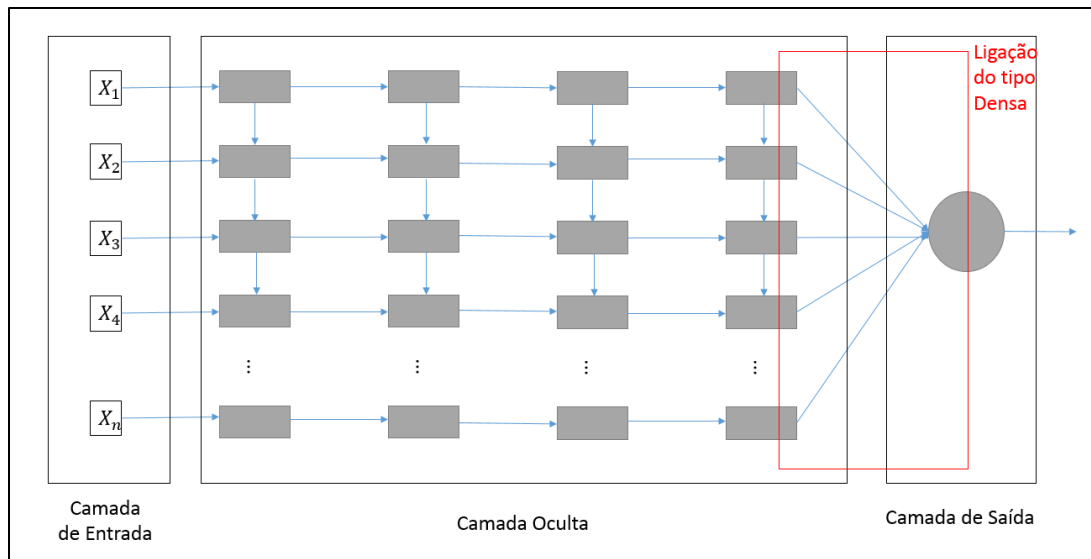
Com os dados normalizados, criou-se um laço de repetição que separou os registros em entrada e saída da Rede Neural Artificial em duas novas matrizes. Usando o exemplo da Figura 17, os registros do índice 1 a 20 de todas as colunas serão inseridos na matriz de previsão, ou seja, a matriz de entrada de dados. O registro da coluna do valor do Dólar do índice 21 será inserido em outra matriz, a de saída de dados. Por se tratar de bases de dados de centenas ou milhares de registros, o laço de repetição criado se encarrega de fazer esta separação, o qual em codificação posterior irá fazer a vinculação das entradas com as saídas para treinamento da rede.

A biblioteca *Keras* possui uma função chamada “*Sequential*”, a qual concatena em sequência as diversas camadas da Rede Neural, que são: camada de entrada, camadas ocultas e a camada de saída. Quanto maior o número de camadas ocultas, mais profunda será a rede. Após alguns testes, verificou-se que uma camada de entrada, quatro camadas ocultas e a camada de saída seriam suficientes para resultados satisfatórios, onde o aumento de camadas não traziam melhoras para o desempenho da rede.

Os neurônios da camada oculta foram declarados como uma rede LSTM, conforme descrito na subseção 2.2.6.8, mas para a camada de saída declarou-se uma rede Densa, que conecta cada saída da camada oculta no Neurônio de saída.

A Figura 18 ilustra a ligação Densa, a qual conecta todos os neurônios anteriores com o neurônio de saída, onde o mesmo utiliza-se da função de ativação linear para classificar os registros de saída. Na mesma figura também pode ser vista a formação das camadas ocultas e de entrada. Os registros de entrada podem variar conforme necessidade, apenas alterando um parâmetro do algoritmo. A quantidade de células de memória da camada oculta também é customizada conforme necessidade e tipo de dados, podendo ampliar ou diminuir para melhor se adaptar aos dados de empresas.

Figura 18: Rede neural implementada



Fonte: Elaborada pelo autor (2019).

Para evitar o *overfitting*, nas camadas de entrada e ocultas, foi realizada a inserção de valores zeros em 15% das entradas de cada camada de neurônios. Com este processo, diminui-se a chance da rede não se adaptar a dados novos, ou seja, não cria o efeito de decorar os dados.

Para a configuração da Rede Neural Artificial o *Keras* possui o método chamado “Compile”, no qual é passado a função de otimização, a função de tratamento de erro e a função de avaliação dos resultados, onde existe várias destas funções implementadas nesta biblioteca.

Para a função de otimização, foi selecionado o otimizador “Adam”. Estas funções foram selecionadas por indicação da própria documentação da biblioteca *Keras*. Para o tratamento do erro utilizou-se a função “mean_squared_error”, a qual trata o erro com o erro quadrático médio. E por fim, a função de avaliação foi configurada a “Mean_Absolute_Error”, que irá fazer a avaliação da acurácia dos resultados a partir erro absoluto médio.

Foram configuradas duas condições de parada de treinamento da Rede Neural Artificial, uma foi a quantidade de épocas, limitada em cem, e a outra condição de parada é o método “EarlyStopping”, que monitora a função do tratamento do erro e se for menor que o valor proposto encerra o treinamento, podendo ser comparado analogamente com a derivada do erro em Redes *feedforward*. Para a rede desenvolvida, foi considerada uma melhora mínima na função do erro de 1×10^{-10} , se por dez épocas a derivada do erro for a mesma, o treinamento encerra. Esta função evita que a rede já treinada e sem tendência de melhora nos resultados pare antes de completar as cem épocas caso necessário.

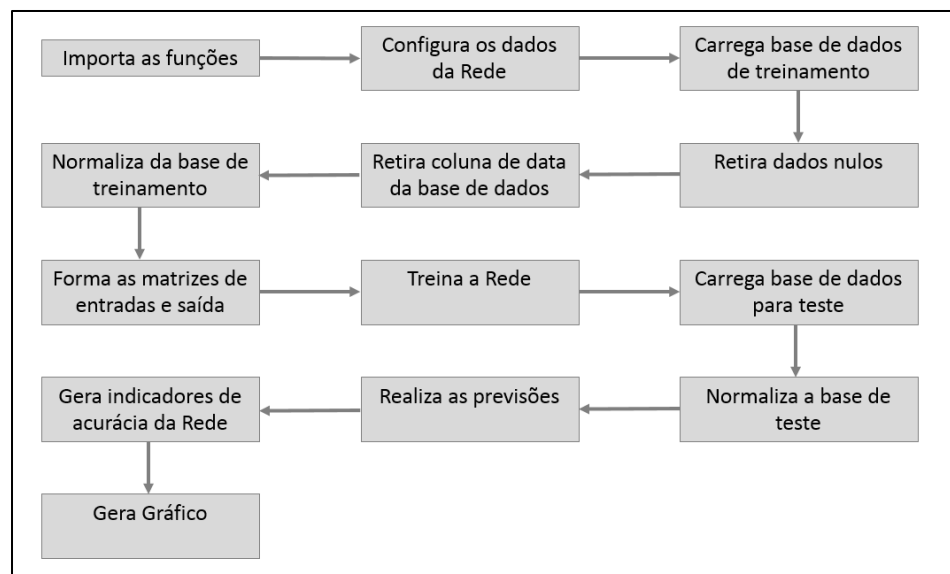
Portanto, com todos os parâmetros da rede configurados, através do método “fit”, se realiza o treinamento da mesma, atualizando os pesos e salvando em um arquivo. Ao término

do treinamento, o algoritmo criado salva os parâmetros da rede e seus pesos, com o intuito de que com novos dados não tenha necessidade de treinar a rede novamente.

Com a fase de treinamento concluída, carrega-se o arquivo, também em formato de dados separados por vírgula de planilha eletrônica, na qual possui a base de registros de validação. Neste caso a organização seleciona a base que irá utilizar de treinamento e a base que irá usar para testes e validação. Por exemplo, se a empresa possui 20 anos de dados históricos, pode usar os últimos dois anos como validação e os outros 18 como treinamento da Rede Neural Artificial. Para o presente trabalho a subseção 3.1 descreve detalhadamente o período utilizado.

Após o carregamento dos dados de validação a Rede faz o mesmo processo anterior realizado na base de dados de treinamento, normaliza, separa em duas matrizes de entradas e saídas e por fim executa a previsão com o método “Predict”, responsável por executar a previsão dos dados. Por fim, o algoritmo gera os indicadores de acurácia de rede e o gráfico da previsão versus o real. A Figura 19 ilustra a sequência da lógica da Rede Neural Artificial desenvolvida, podendo visualizar a sequência de etapas para a execução do algoritmo.

Figura 19: Fluxograma do código fonte



Fonte: Elaborada pelo autor (2019).

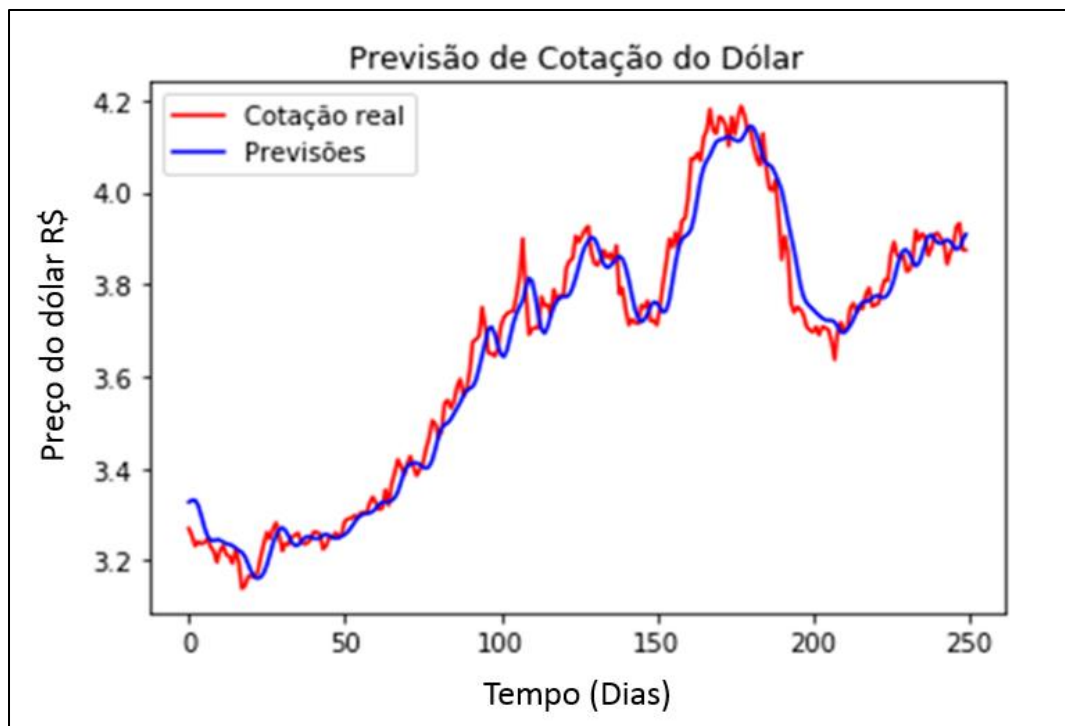
4 RESULTADOS

Com o desenvolvimento da Rede Neural de forma a se adaptar a qualquer tipo de dado numérico, seguido do seu treinamento e ao fim gerando as previsões e resultado dos indicadores de acurácia da rede, nota-se uma facilidade na adaptação dos registros sem muito controle do gestor, mas em contrapartida a rede se comporta com melhor eficácia em base de dados maiores, na qual com base de dados com menos de 500 registros a mesma possui erros de acurácia predição maiores comparados a uma base de dados com mais de 1000 registros.

4.1 PREVISÃO DO DÓLAR AMERICANO

Na previsão do dólar americano, por se tratar de uma base de registros de mais de 5000 dados preditivos e, outro fator importante, com registros continuados, ou seja, registros diários, a Rede Neural Artificial forneceu um resultado satisfatório, como pode ser visto na Figura 20.

Figura 20: Previsão do dólar americano



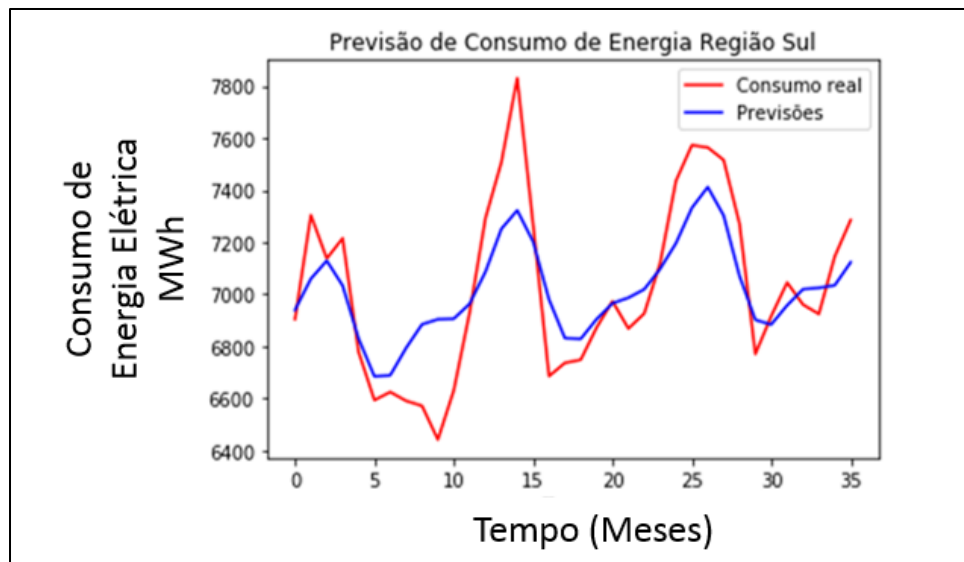
Fonte: Elaborada pelo autor (2019).

A medida de erro utilizada além da MAPE e RMSE foi a MAE. Com estes três indicadores, pode-se medir a acurácia e efetividade do algoritmo. Portanto, para a previsão do dólar utilizou-se duzentos registros anteriores e obteve-se como resultado um erro MAPE 1,062%, MAE de 0,039 e RMSE de 0,05044.

4.2 PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA

Para a previsão do consumo de energia elétrica do sul do Brasil, por se utilizar uma base mensal, onde o consumo de energia na prática é diário, conseqüentemente o resultando do banco de dados é menor. Se comparar os resultados com a predição do Dólar, o erro da previsão do consumo de energia ficou maior. A Figura 21 apresenta um gráfico comparativo da curva da previsão versus o consumo real, demonstra um acompanhamento na tendência mas ainda não consegue identificar picos esporádicos. Entretanto realizado o treinamento com 20 meses anteriores os erros ficaram a níveis aceitáveis sendo MAPE de 2,157%, MAE de 152,15 e RMSE de 192,97, na qual a unidade de medida é MWh.

Figura 21: Previsão de consumo de energia elétrica da Região Sul do Brasil

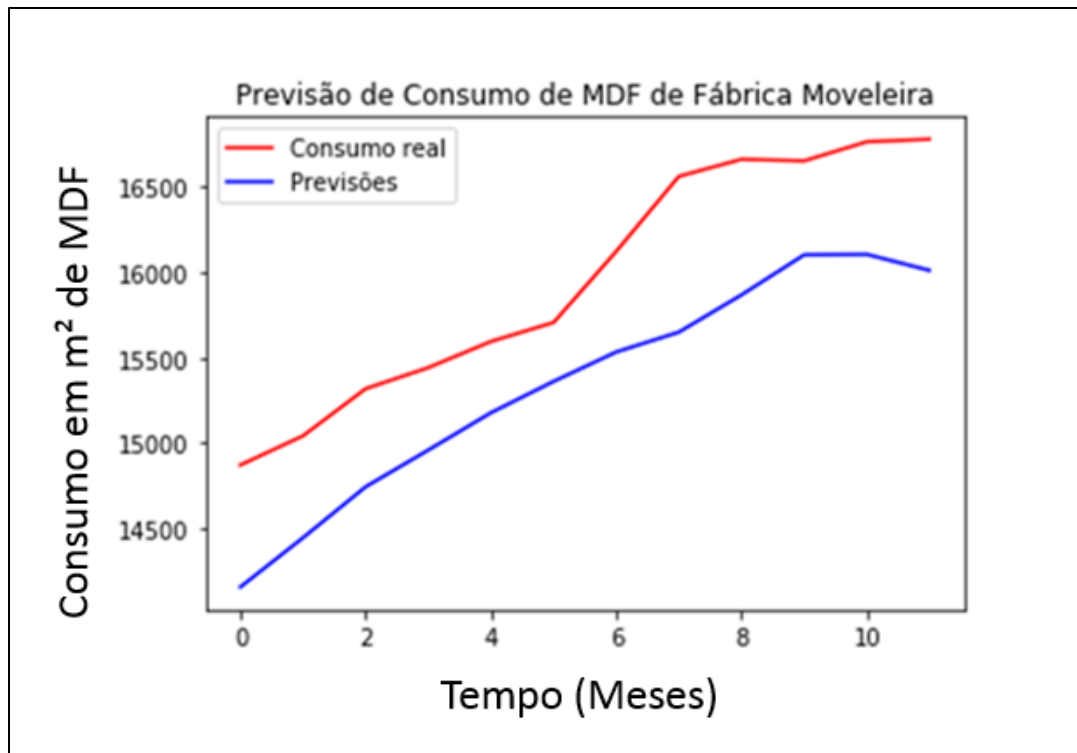


Fonte: Elaborada pelo autor (2019).

4.3 PREVISÃO DE DEMANDA PARA FÁBRICA MOVELEIRA

Por fim e como um exemplo de base de dados menor, realizou-se a previsão do consumo mensal de chapas de MDF em metros quadrados de uma fábrica moveleira da Serra Gaúcha. Por possuir uma base de registros menor de quinhentas unidades, os resultados encontrados possuem uma acurácia significativamente menor se comparado às previsões anteriores. Utilizando doze registros anteriores para treinamento da Rede, obteve-se um erro MAPE de 3,85%, MAE de 616,92 e um RMSE de 636,34. A Figura 22 ilustra graficamente a previsão realizada e o consumo real, podendo ser visto o afastamento entre curvas, demonstrando a dificuldade que Redes LSTM possuem para se adaptar a bases de dados menores.

Figura 22: Previsão de consumo de MDF de fábrica moveleira



Fonte: Elaborada pelo autor (2019).

O Quadro 11 descreve os erros encontrados nas previsões de cada organização. Percebe-se que a continuidade dos registros preditivos e a sua quantidade influenciam no resultado de forma positiva. Contudo, outros resultados podem ser obtidos de variações na configuração da Rede Neural Artificial ou adicionando/alterando outros indicadores econômicos e variáveis que influenciam na demanda a ser prevista, podendo melhorar sua performance.

Quadro 11: Erros das previsões

Estatística	Dólar	Energia	MDF
MAPE	1,062%	2,157%	3,85%
MAE	0,039	152,15	616,92
RMSE	0,05044	192,97	636,34

Fonte: Elaborada pelo autor (2019).

5 CONCLUSÕES

As ferramentas de previsão são importantes para a gestão de uma organização, podendo economizar recursos em geral e até mesmo gerar indicadores para investimentos a curto e médio prazo para a empresa. Os métodos convencionais de previsão de demanda, por utilizar apenas o histórico passado, sabendo que todo produto possui dependência com outras áreas, mostra-se pouco eficaz pois a empresa precisa atribuir todas as possíveis variáveis que influenciam em seu processo para realmente obter um resultado preditivo mais próximo do real, principalmente em um mercado oscilante. Estes métodos convencionais de previsão, também, necessitam de conhecimento teórico do gestor para a sua aplicação, podendo ocorrer equívocos na análise dos dados.

O presente trabalho foi conduzido com o princípio de desenvolver, através de inteligência artificial, um algoritmo que o gestor não fique refém somente do histórico passado e sim, que possa apresentar realmente todas as variáveis que influenciam seu produto, consumo ou outro objeto que deseja fazer a previsão. Além deste fator, o objetivo era que o algoritmo fosse adaptativo, independentemente da quantidade de registros ou indicadores o gestor utilizaria o mesmo com sucesso na análise.

Através dos resultados obtidos, conclui-se que a Rede Neural LSTM possui um pré-requisito para atingir seu melhor resultado que é a quantidade de dados para a predição, ou seja, quanto maior a base de dados para treinamento maior será acurácia e eficiência da ferramenta de previsão.

Entretanto, com a base de registros preditivos, o tempo de processamento para treinamento da Rede Neural eleva significativamente, podendo ficar dias para conseguir finalizar conforme tamanho da base de dados, mas após esta etapa, a previsão é realizada com muita rapidez.

Em função da fácil adaptação aos dados das organizações, o presente trabalho se mostra como uma adequada ferramenta de previsão, pois administradores/gestores podem, através de seu conhecimento na área, atribuir realmente variáveis que influenciam no processo e pode também, atribuindo em formato de números, treinar a Rede Neural Artificial com seu conhecimento do mercado. A ferramenta, também, mostrou-se ágil e prática, chegando a resultados aceitáveis, nos quais o erro MAPE não ultrapassou 4% nem no pior caso que é onde a base de dados é menor.

A ferramenta desenvolvida aliada ao conhecimento do gestor pode gerar resultados úteis nas organizações, pois pode diminuir o volume de compra, reduzindo estoque, controle de

carga horária de funcionários, na qual pode prever a venda futura e assim saber a necessidade de trabalho de seu colaborador ou novos contratos.

No campo energético, esta ferramenta pode analisar e auxiliar empresas de gestão de energia, onde operam com contratos milionários podendo haver uma pequena variação percentual, portanto o trabalho desenvolvido se torna de grande valia para maioria das organizações.

6 TRABALHOS FUTUROS

O presente trabalho abre campo para novas pesquisas na área de inteligência artificial. Esta área possui um vasto campo em crescimento, sendo utilizada em diversas aplicações. A partir desta obra, pode-se fazer um estudo comparativo entre métodos convencionais de previsão de demanda e Redes Neurais Recorrentes.

Pode-se pesquisar também, as Redes recorrentes GRU (*gated recurrent units*) fazendo um comparativo com os resultados da Rede LSTM, podendo descobrir padrões onde uma pode ter uma melhor performance que a outra.

Outro campo a ser aplicado é a previsão de longo prazo, fazendo melhorias no algoritmo atual onde sua previsão pode ser de dias, meses ou anos no futuro, podendo prever um espaço de tempo maior.

REFEÊNCIAS

- AL-SABA, T., EL-AMIN, I. Artificial neural networks as applied to long-term demand forecasting. **Artificial Intelligence in Engineering**. [S.l.], v. 13, n. 2, p. 189-197, abril 1999.
- ANEEL - AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Atlas de energia elétrica do Brasil**. 3. ed. Brasília: Aneel, 2008.
- BITTENCOURT, G. **Inteligência artificial: Ferramentas e teorias**. 3. ed. Florianópolis: UFSC, 2006.
- BOX, P.; JENKINS, G. M. **Time series analysis: forecasting and control**. 1. ed. San Francisco: Holden-day Inc, 1976.
- CAMPOS, R. J. **Previsão de séries temporais com aplicações a séries de consumo de energia elétrica**. 2008. 110 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Minas Gerais. Belo Horizonte, 2008.
- CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior. **Capes**. Disponível em: <<https://www.capes.gov.br/>>. Acesso em: 15 mar. 2019.
- CAVALHEIRO, D. **Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos**. 2003. 137 f. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal de Santa Catarina. Florianópolis, 2003.
- CORRÊA, H. L.; CORRÊA, C. A. **Administração de produção e operações: manufaturas e serviços: uma abordagem estratégica**. 1. ed. São Paulo: Atlas, 2004.
- DASH, P. K.; LIEW A. C.; RAMAKRISHNA G. Power-demand forecasting using a neural network with an adaptive learning algorithm. **IEEE Proceedings: Generation, Transmission and Distribution**, [S.l.], v. 142, n. 6, p. 560-568, nov. 1995.
- DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentos da administração da produção**. 3. ed. Porto Alegre: Bookman, 2001.
- ELSEVIER. **Elsevier**, 2018. Disponível em: <www.elsevier.com>. Acesso em: 02 mar. 2019.
- GHIASSI, G., ZIMBRA, D.K., SAIDANE, H. Urban water demand forecasting with a dynamic artificial neural network model. **Journal of Water Resources Planning and Management**. [S.l.], v. 134, n. 2, mar. 2008.
- HAIR, J. F. *et al.* **Multivariate Data Analysis**. 7. ed. New Jersey: Prentice Hall, 2010.
- HAYKIN, S. **Redes Neurais: princípio e prática**. 2. ed. Porto Alegre: Bookman, 2001.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. New Jersey: Prentice Hall, 2009.

HILTZ, F. F. Analog Computer Simulation of a Neural Element. IRE Transactions on Bio-Medical Electronics. **IEEE**, [S.l.], n. 9, p. 12-20, 1962.

HONAISER, E. H. R.; SAUAIA, A. C. A. Desenvolvimento e aplicação de um modelo para previsão de demanda em jogos de empresas. **RAC-Eletrônica**, [S.l.], v. 2, n. 3, p. 470-485, 2008.

JAIN, A.; VARSHNEY, A. K.; JOSHI, U. C. Short-term water demand forecast modelling at IIT kanpur using artificial neural networks. **Water Resources Management**, Kanpur, v. 15, n.5, p. 299–321, out. 2001.

KOURENTZES, N. Intermittent demand forecasts with neural networks. **International Journal of Production Economics**, [S.l.], v. 143, n. 1, p. 198-206, maio 2013.

KOTLER, P. **Administração de marketing: análise, planejamento, implementação e controle**. 5. ed. São Paulo: Atlas, 1998.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**. 1. ed. São Paulo: Editora Acadêmica São Paulo, 1996.

LAS CASAS, A. L. **Administração de vendas**. 8. ed. São Paulo: Atlas, 2012.

LIMA, R. R. D. D. **Análise comparativa de previsão por meio de modelos econométricos e redes neurais**. 2014. 75 f. Dissertação (Mestrado de Engenharia de Produção) - Pontifícia Universidade Católica de Goiás. Goiânia, 2014.

LUGER, G. F. **Inteligência artificial: estruturas e estratégias para a solução de problemas complexos**. 4. ed. Porto Alegre: Bookmann, 2004.

MALHOTRA, N. K. **Pesquisa de marketing - uma orientação aplicada**. 6. ed. São Paulo: Bookman, 2011.

MARTINS, G. D. A. **Estatística geral e aplicada**. 1. ed. São Paulo: Atlas, 2001.

MATARIC, M. J. **Introdução à robótica**. 1. ed. São Paulo: Blucher, 2014.

MOREIRA, D. A. **Administração da produção e operações**. 1. ed. São Paulo: Pioneira Thomson Learning, 1993.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blüncher, 2006.

NELSON, D. M. Q. **Uso de redes neurais recorrentes para previsão de séries temporais financeiras**. 2017. 73 f. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Minas Gerais. Belo Horizonte, 2017.

PASCHOALINO, F. F. *et al.* Previsão de demanda de energia elétrica no Brasil. In XVIII SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA, 2007, Rio de Janeiro. **Anais [...]**.Rio de Janeiro: SPOLM, 2007.

PERINI, N. B.; BERTOLDE, A. I. Previsão de demanda na indústria de petróleo: um estudo de caso no estado do Espírito Santo. **Revista Gestão Industrial**, Paraná, v.12, n.1, p. 156-182, 2016.

REIS, J. G. M. *et al.* Previsão de demanda no mercado de varejo: um estudo de caso em um comércio de baterias automotivas. **South American Development Society Journal**, [S.l.], v. 1, n. 1, p. 1 - 16, 2015.

RICH, E.; KNIGHT, K. **Artificial intelligence**. 2. ed. New York: McGraw-Hill, 1991.

RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da Produção e Operações**. 3. ed. São Paulo: Pearson Prentice Hall, 2004

ROMERA, E. G.; MORAN, M.A.J.; FERNANDEZ D. C. Monthly Electric Energy Demand Forecasting Based on Trend Extraction. **IEEE Transactions on Power Systems**. [S.l.], v. 21, n. 4, p. 1946-1953, out. 2006.

RODRIGUES, V. **Como máquinas aprendem: fundamentos e algoritmos de machine learning, redes neurais e deep learning**. 1. ed. Florença: [s.n.], 2018.

SCOPUS. **Scopus**. Disponível em: <https://www.scopus.com/>. Acesso em 97 mar. 2019.

SILVA, D. M. D. Python: história e ascendência. **Programar**, Dourados, n. 59, p. 96-99, fev. 2018.

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas: fundamentos teóricos e aspectos práticos**. 2. ed. São Paulo: Artliber, 2016.

SOUZA, R. C.; CAMARGO, M. E. **Análise e previsão de séries temporais: os modelos ARIMA**. 2 ed. Rio de Janeiro: Regional, 2004.

SPIRO, R. L.; RICH, G. A.; STANTON, W. J. **Gestão da força de vendas**. 10. ed. Porto Alegre: AMGH, 2010.

SRINIVASAN, D. ; CHANG, C.S.; LIEW, A. C. Demand forecasting using fuzzy neural computation, with special emphasis on weekend and public holiday forecasting. **IEEE Transactions on Power Systems**, [S.l.], v. 10, n. 4, p. 1897-1903, nov. 1995.

STANTON, K. N.; GUPTA, P. C.; EL-ABIAD, A. H. Long range demand forecasting for the electric utility industry. **EEE**, Denver, v. 6, jan 1969.

TRIOLA, M. F. **Introdução a estatística**. 10. ed. Rio de Janeiro: LTC, 2008.

TUBINO, D. F. **Manual de planejamento e controle da produção**. 2. ed. São Paulo: Atlas, 2000.

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática**. 2. ed. São Paulo: Atlas, 2009.

WERNER, L. Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião. 2004. 166 f. Tese (Doutorado em Engenharia de Produção) - Universidade Federal do Rio Grande do Sul. Porto Alegre, 2004.