

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Tafarel Franco Milke

**METODOLOGIA PARA PREVISÃO DE CARGA NO HORIZONTE DE
CURTO PRAZO UTILIZANDO REDES NEURAIIS**

Santa Maria, RS
2019

Tafarel Franco Milke

**METODOLOGIA PARA PREVISÃO DE CARGA NO HORIZONTE DE CURTO
PRAZO UTILIZANDO REDES NEURAIIS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, na Área de Concentração em Processamento de Energia Elétrica, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do título de **Mestre em Engenharia Elétrica**.

Orientadora: Prof^a. Dr^a. Alzenira da Rosa Abaide

Santa Maria, RS
2019

Ficha catalográfica elaborada através do Programa de Geração Automática
da Biblioteca Central da UFSM, com os dados fornecidos pelo autor.

Milke, Tafarel Franco Milke
METODOLOGIA PARA PREVISÃO DE CARGA NO HORIZONTE DE
CURTO PRAZO UTILIZANDO REDES NEURAIIS / Tafarel Franco
Milke Milke.- 2019.
82 p.; 30 cm

Orientadora: Alzenira da Rosa Abaide
Dissertação (mestrado) - Universidade Federal de Santa
Maria, Centro de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, RS, 2019

1. Previsão de Carga 2. Redes Neurais Artificiais 3.
Curto Prazo I. da Rosa Abaide, Alzenira II. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

©2019

Todos os direitos autorais reservados a Tafarel Franco Milke. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

Endereço: Av. Getúlio Vargas, 1454, Bairro Assis Brasil, Ijuí, RS, CEP: 98700-000.

Fone: (0xx)55 3331 7718; E-mail: tafarelmilke@gmail.com

Tafarel Franco Milke

**METODOLOGIA PARA PREVISÃO DE CARGA NO HORIZONTE DE CURTO
PRAZO UTILIZANDO REDES NEURAIAS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, na Área de Concentração em Processamento de Energia Elétrica, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do título de **Mestre em Engenharia Elétrica**.

Aprovado em 28 de agosto de 2019:



Alzenira da Rosa Abaide, Dra. (UFSM)
(Presidente/Orientador)



Laura Lisiane Callai dos Santos, Dra. (UFSM)



Maurício de Campos, Dr. (UNIJUÍ)

Santa Maria, RS
2019

DEDICATÓRIA

À Deus e a minha família.

AGRADECIMENTOS

Agradeço a Deus por ter me guiado e sustentado a cada dia, pela força e capacidade que meu deus para concluir mais essa etapa em minha vida.

A minha orientadora, Prof^a. Alzenira da Rosa Abaide, minha profunda gratidão pela confiança, pelo apoio, incentivo e pelos ensinamentos prestados.

A Universidade Federal de Santa Maria (UFSM) e ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) pela infraestrutura disponibilizada para o desenvolvimento deste trabalho.

Ao Instituto de Desenvolvimento Rural (IRDER) da Universidade Regional do Noroeste do Estado Rio Grande do Sul (UNIJUÍ) pela disponibilização do banco de dados com as medições das variáveis climáticas.

A minha esposa Jéssica, pelo amor, incentivo, apoio, companheirismo e compreensão nos momentos dedicados aos meus estudos.

A meu pai Ildo (in memoriam), minha mãe Fátima pela educação, apoio e incentivo aos estudos.

Aos meus sogros, João e Solange, minha cunhada Rebeca pela parceria, incentivo e o apoio em todos os momentos de minha vida.

Ao meu amigo Artur Poffo pelo auxílio na formatação deste trabalho.

A minha amiga Sandy, pelos auxílios no melhoramento do modelo utilizado e nas parcerias de publicações.

Aos meus colegas e amigos do DEMEI pelo apoio, incentivo, convívio e a troca de experiências.

“Mas, buscai primeiro o reino de Deus, e a sua justiça, e todas estas coisas vos serão acrescentadas”. Mateus 6:33

RESUMO

METODOLOGIA PARA PREVISÃO DE CARGA NO HORIZONTE DE CURTO PRAZO UTILIZANDO REDES NEURAIS

AUTOR: Tafarel Franco Milke

ORIENTADORA: Prof^a Dr^a Alzenira da Rosa Abaide

Atualmente a competitividade e a inserção de novas tecnologias no setor elétrico condicionam empresas a encontrar formas de melhorar a qualidade da prestação dos seus serviços e garantir lucratividade. A atividade de previsão de carga no curto prazo é indispensável para subsidiar o planejamento e a operação dos sistemas elétricos, visando tornar a oferta de energia estável e confiável. Para realizar a previsão de carga utilizando Redes Neurais Artificiais (RNA) é necessário avaliar as variáveis envolvidas no comportamento da curva de carga diária. Através da avaliação e obtenção das variáveis disponíveis mais influentes no comportamento da carga, é possível então utiliza-las como entrada do modelo RNA adotado. As redes neurais artificiais são modelos computacionais inspirados na simplificação do funcionamento dos neurônios biológicos, com a capacidade de aprendizado a partir da experiência com as entradas do sistema. São semelhantes ao cérebro devido às características de conhecimento adquirido por um processo de aprendizagem e conexões entre seus neurônios utilizadas para armazenar o conhecimento adquirido. Uma rede neural possuiu alto poder de generalizar informações após uma fase de aprendizagem, possibilitando capturar relações funcionais entre os dados produzindo uma saída próxima daquela esperada. O processo de aprendizagem ou treinamento da rede consiste na aplicação de etapas ordenadas necessárias para que ocorra a sintonização dos pesos sinápticos e limiares de seus neurônios, visando à produção da generalização de soluções pelas suas saídas. O objetivo do treinamento da rede é tornar a aplicação de um conjunto de entradas em um conjunto de saídas desejadas. As ferramentas utilizando as técnicas de inteligência artificial vêm sendo aperfeiçoadas, permitindo a sua aplicação em diversas áreas do conhecimento, se destacando entre as principais técnicas utilizadas para realizar previsão de carga no curto prazo, sendo atualmente muito pesquisadas e empregadas para este fim. Desse modo, a sua utilização vem demonstrando resultados mais acurados em relação aos métodos tradicionais, pois conseguem desenvolver de melhor forma o processamento matemático requerido. Este trabalho apresenta uma proposta de previsão da curva de carga diária para um dia à frente aplicado a dados reais de energia, demanda e temperatura, pois são as variáveis que melhor representam o comportamento da carga no curto prazo; para isto foi implementado um modelo desenvolvido com redes neurais *perceptron* de múltiplas camadas, utilizando o algoritmo de aprendizagem *Levenberg-Marquardt*. Os resultados encontrados foram satisfatórios e aceitáveis comparados aos apresentados na revisão bibliográfica, sendo suficientes para aplicação prática atendendo a proposta deste trabalho.

Palavras-chave: Previsão de Carga. Redes Neurais Artificiais. Curto Prazo.

ABSTRACT

METHODOLOGY FOR SHORT-TERM HORIZON LOAD FORECASTING USING NEURAL NETWORKS

AUTHOR: Tafarel Franco Milke
ADVISOR: Prof^a Dr^a Alzenira da Rosa Abaide

Competitiveness and the insertion of new technologies in the electricity sector now condition companies to find ways to improve the quality of their services and ensure profitability. The short-term load forecasting activity is indispensable to support the planning and operation of electrical systems, aiming to make the energy supply stable and reliable. To perform load prediction using Artificial Neural Networks (ANN), it is necessary to evaluate the variables involved in the behavior of the daily load curve. By evaluating and obtaining the most available variables influencing the load behavior, it is then possible to use them as input to the adopted ANN model. Artificial neural networks are computational models inspired by the simplification of the functioning of biological neurons, with the ability to learn from experience with system inputs. They are similar to the brain due to the characteristics of knowledge acquired by a learning process and connections between its neurons used to store the acquired knowledge. A neural network has high power to generalize information after a learning phase, allowing to capture functional relationships between data producing output close to the expected. The process of learning or training the network consists in the application of ordered steps necessary for the tuning of the synaptic weights and thresholds of their neurons, aiming to produce the generalization of solutions by their outputs. The goal of network training is to make the application of a set of inputs a set of desired outputs. The tools using artificial intelligence techniques have been improved, allowing their application in various areas of knowledge, standing out among the main techniques used to perform short-term load forecasting, and are currently widely researched and employed for this purpose. Thus, its use has been showing more accurate results compared to traditional methods, since they can better develop the required mathematical processing. This paper presents a proposal for the prediction of the daily load curve for one day ahead applied to real energy, demand and temperature data, since it is the variables that best represent the short-term load behavior; For this, a model developed with multilayer perceptron neural networks using the Levenberg-Marquardt learning algorithm was implemented. The results found were satisfactory and acceptable compared to those presented in the literature review, being sufficient for practical application meeting the proposal of this work.

Keywords: Load Forecast. Artificial neural networks. Short term.

LISTA DE FIGURAS

Figura 1 – Neurônio artificial	35
Figura 2 – Gráfico da função logística	37
Figura 3 – Gráfico da função tangente hiperbólica.....	38
Figura 4 – Gráfico da função gaussiana	39
Figura 5 – Gráfico da função linear	39
Figura 6 – Rede Perceptron de camada simples	41
Figura 7 – Rede Perceptron de múltiplas camadas	42
Figura 8 – Rede Perceptron realimentada.....	43
Figura 9 – Visão geral para previsão de carga.....	50
Figura 10 – Correlação temperatura x demanda.....	53
Figura 11 – Rede RNA - Multilayer Perceptron.....	54
Figura 12 – Fluxograma do modelo computacional desenvolvido.....	55
Figura 13 – Interface do sistema desenvolvido	59
Figura 14 – Exemplo de treinamento da RNA	60
Figura 15 – Exemplo de resultado do treinamento da RNA.....	61
Figura 16 – Exemplo de resultado da projeção de curva de carga	61
Figura 17 – Projeção curva de carga integralizada em 15 minutos do dia 29/01/2017	66
Figura 18 – Projeção curva de carga integralizada em 60 minutos do dia 29/01/2017	67
Figura 19 – Projeção curva de carga integralizada em 15 minutos do dia 26/03/2019	68
Figura 20 – Projeção curva de carga integralizada em 60 minutos do dia 26/03/2019	69
Figura 21 – Projeção curva de carga integralizada em 15 minutos do dia 29/01/2017	70
Figura 22 – Projeção curva de carga integralizada em 60 minutos do dia 29/01/2017	70
Figura 23 – Projeção curva de carga integralizada em 15 minutos do dia 28/03/2019	71
Figura 24 – Projeção curva de carga integralizada em 60 minutos do dia 28/03/2019	72

LISTA DE TABELAS

Tabela 1 – Resumo revisão bibliográfica.....	31
Tabela 2 – Configurações da rede utilizadas para as simulações da SE-1.....	62
Tabela 3 – Configurações da rede utilizadas para as simulações da SE-2.....	62
Tabela 4 – Configurações da rede para simulações com dados da SE-1	64
Tabela 5 – Configurações da rede para simulações com dados da SE-2	64
Tabela 6 – Análise comparativa do MAPE nas projeções realizadas	73

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
APE	Erro percentual absoluto
ARIMA	Auto Regressive Integrated Moving Average
ARMA	Auto Regressive Moving Average
ARMAX	Auto Regressive Moving Average Model with external input
ART	<i>Adaptive Resonance Theory</i>
EPE	Empresa de Pesquisa Energética
FF-DNN	<i>Feedforward Deep Neural Network</i>
FFNN	<i>Feedforward</i> de Redes Neurais
GRNN	Rede neural de regressão generalizada
LM	Levenberg-Marquardt
LSTM	<i>Long Short-term Memory</i>
MAPE	Erro percentual absoluto médio
MLP	Rede Perceptron de múltiplas camadas
MSE	Erro mínimo quadrático
NN	Neural networks
kW	kilowatt
kVA	kilovoltampere
PRODIST	Procedimentos de Distribuição
R-DNN	<i>Recurrent Deep Neural Network</i>
RNA	Redes Neurais Artificiais
RNN	Redes neurais recorrentes
SARIMA	Seasonal Auto Regressive Integrated Moving Average
SCADA	Sistemas de Supervisão e Aquisição de Dados
SIN	Sistema Interligado Nacional
SE	Subestação
SEP	Sistema Elétrico de Potência
UFSM	Universidade Federal de Santa Maria

LISTA DE SÍMBOLOS

a_j	valor real
β	constante real
c	parâmetro de definição do centro da função gaussiana
C°	temperatura em graus celsius
$d_j(k)$	valor desejado
D	demanda, expressa em kW ou kVA
$D_{Original}$	demanda original
D_M	demanda média
$D_{mínima}$	demanda mínima
$D_{máxima}$	demanda máxima
D_r	demanda real
$D(t)$	variação da demanda no tempo
e	função exponencial
$E(k)$	erro quadrático médio
E	matriz identidade
Σ	combinador linear
g	função de ativação
$J(W)$	matrizes jacobianas
N	número de períodos ou amostras
T	período de tempo
x_n	sinais de entrada
θ	limiar de ativação
σ	desvio padrão
u	potencial de ativação
μ	taxa de convergência do algoritmo <i>Levenberg-Marquardt</i>
w_n	pesos sinápticos
x	dados normalizados
y	signal de saída
Y_j	valor produzido pelo neurônio de saída

SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	JUSTIFICATIVA E MOTIVAÇÃO.....	17
1.2	OBJETIVOS.....	18
1.2.1	Objetivo geral.....	18
1.2.2	Objetivos específicos.....	18
1.3	ORGANIZAÇÃO DA DISSERTAÇÃO.....	19
2	REVISÃO BIBLIOGRÁFICA.....	20
2.1	ESTADO DA ARTE PREVISÃO DE DEMANDA UTILIZANDO RNA.....	20
2.2	MODELOS DE PREVISÃO DE CARGA.....	21
2.2.1	Previsão de longo prazo.....	22
2.2.3	Previsão de curto prazo.....	23
2.2.4	Previsão de curtíssimo prazo.....	30
2.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	31
3	REDES NEURAIS ARTIFICIAIS.....	33
3.1	INTRODUÇÃO.....	33
3.2	CONCEITOS INICIAIS.....	34
3.2.1	Funções de ativação.....	36
3.2.1.1	Função logística.....	37
3.2.1.2	<i>Função tangente hiperbólica.....</i>	37
3.2.1.3	<i>Função gaussiana.....</i>	38
3.2.1.4	<i>Função linear.....</i>	39
3.2.2	Arquiteturas das RNA.....	40
3.2.2.1	<i>Arquitetura feedforward de camada simples.....</i>	40
3.2.2.2	<i>Arquitetura feedforward de camadas múltiplas.....</i>	41
3.2.2.3	<i>Arquitetura recorrente ou realimentada.....</i>	42
3.2.3	Rede RNA com arquitetura de rede perceptron.....	43
3.2.3.1	<i>Arquitetura de redes perceptron multicamadas.....</i>	44
3.3	TREINAMENTO DA RNA.....	45
3.3.1	Treinamento supervisionado.....	45
3.3.2	Treinamento não supervisionado.....	46
3.3.3	Algoritmo de treinamento.....	46
3.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	49
4	METODOLOGIA UTILIZANDO REDES NEURAIS NA PREVISÃO DO HORIZONTE DE CURTO PRAZO.....	50
4.1	FATORES INFLUENTES NA DEMANDA.....	51
4.1.1	Dados de entrada do sistema.....	52
4.1.2	Normalização dos dados.....	53
4.2	MODELO COMPUTACIONAL DESENVOLVIDO BASEADO EM RNA.....	54
4.3	TREINAMENTO DA REDE.....	56
4.3.1	Algoritmo para Treinamento dos Dados de Entrada.....	57
4.3.2	Indicador de erro de previsão.....	57
4.4	SIMULAÇÃO DA REDE.....	58
4.4.1	Configuração e parametrização da rede.....	58
4.4.2	Hardware utilizado.....	63
4.5	INTERFACE GRÁFICA.....	63
4.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	63

5	ANÁLISE DOS RESULTADOS DO ESTUDO DE CASO	64
5.1	SIMULAÇÕES SE-1.....	65
5.1.1	Simulações SE-1 – Curva de Carga do dia 29/01/2017.....	65
5.1.2	Simulações SE-1 – Curva de Carga do dia 26/03/2019.....	67
5.2	SIMULAÇÕES SE-2.....	69
5.2.1	Simulações SE-2 – Curva de Carga do dia 29/01/2017.....	69
5.2.2	Simulações SE-2 – Curva de Carga do dia 28/03/2019.....	71
5.3	ANÁLISE COMPARATIVA DAS SIMULAÇÕES	72
5.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	73
6	CONSIDERAÇÕES FINAIS.....	75
6.1	CONCLUSÕES.....	75
6.2	OPORTUNIDADES PARA TRABALHOS FUTUROS.....	76
6.3	PUBLICAÇÕES.....	77
	REFERÊNCIAS	78

1 INTRODUÇÃO

A energia elétrica atualmente é um dos produtos mais importantes para a sustentabilidade da sociedade, sendo a segunda maior fonte de energia primária consumida no Brasil (17,5%), e em breve deverá ultrapassar a fonte primária mais utilizada, o óleo diesel (18,1%) (EPE, 2019).

Ela se tornou indispensável para o desenvolvimento da sociedade, trazendo facilidade, conforto e qualidade de vida ao ser humano. A facilidade para realizar a sua conversão e para o seu transporte impactou diretamente no desenvolvimento e modernização da sociedade e do sistema elétrico brasileiro.

No princípio, a grande preocupação era em disponibilizar a eletricidade aos serviços públicos, principalmente iluminação e transporte, posteriormente para as unidades industriais. No entanto, se tornou um produto essencial para o desenvolvimento, a expansão e modernização do setor elétrico.

Sendo assim, tornou-se necessário a preocupação de não apenas disponibilizar a energia elétrica, mas fornecê-la com qualidade e confiabilidade, para isto necessitou a definição de parâmetros pelo agente regulador, através da criação do módulo 8 dos Procedimentos de Distribuição (PRODIST) da Agência Nacional de Energia Elétrica (ANEEL) foi estabelecido as características de qualidade, com o objetivo de chegar ao consumidor final dentro de parâmetros aceitáveis, refletindo assim na melhor qualidade de prestação dos serviços de geração, transmissão e distribuição.

Atualmente no Sistema Interligado Nacional (SIN), a eletricidade precisa ser consumida assim que gerada, sendo necessário então o equilíbrio constante entre a produção e o consumo para garantir a sua estabilidade.

A curva de carga diária de um sistema elétrico pode ser expressa através da forma em que os clientes utilizam a energia elétrica ao longo do dia, pois a carga é variável em função do uso dos equipamentos eletroeletrônicos dos consumidores (GASTALDELLO, 2017).

A previsão de carga no sistema elétrico de potência é uma das principais atividades para o seu planejamento, pois, ela dará suporte ao desenvolvimento de diversas atividades de planejamento e operação, apoiando os processos decisórios para o aumento da capacidade de atendimento ao mercado consumidor.

Nos últimos anos vários métodos e técnicas foram utilizados para realizar a previsão de carga, tais como: modelos estatísticos, modelos utilizando inteligência artificial e métodos híbridos, propondo previsões mais precisas e confiáveis.

Portanto, percebe-se que nos últimos anos com o avanço da tecnologia, pesquisadores e empresas procuraram intensificar seus esforços para realizar o desenvolvimento de técnicas melhores e mais aperfeiçoadas, com o objetivo de tornar os resultados das previsões mais eficientes e satisfatórios.

A previsão de carga no curto prazo tem por objetivo orientar e atuar no planejamento da operação dos sistemas elétricos, auxiliando nas atividades de programação de despacho da geração, planejamento de manutenções, análise de confiabilidade e o gerenciamento da demanda em sistemas de distribuição.

Vários fatores podem influenciar no comportamento da carga de um sistema elétrico, e as variáveis mais influentes podem auxiliar os modelos de previsão a reproduzir uma projeção de carga mais próxima da realidade (BENTO et al., 2019).

Esse trabalho tem como proposta realizar a previsão de cargas elétricas no horizonte de curto prazo, para projetar a curva de carga de um dia à frente, com um modelo matemático desenvolvido com base nas técnicas de Redes Neurais Artificiais (RNA), utilizando a arquitetura *Perceptron* de múltiplas camadas (MLP).

As variáveis de entrada do sistema são dados reais de uma distribuidora de energia elétrica e medidas de variáveis climáticas locais, elas foram escolhidas levando em consideração o seu impacto no comportamento da curva de carga. Estes dados são utilizados para realizar a aprendizagem da rede através da implementação de um algoritmo de treinamento chamado *Levenberg-Marquardt* (LM). A solução do problema baseia-se no treinamento da rede neural considerando as variáveis de entradas escolhidas.

1.1 JUSTIFICATIVA E MOTIVAÇÃO

Nos últimos anos a utilização de técnicas e ferramentas computacionais ganhou espaço, força e incentivo por diversas instituições e empresas do setor elétrico brasileiro. Nesse sentido, percebe-se que com o avanço da tecnologia ocorreu à adesão a novas tecnologias no meio de trabalho das empresas e dos engenheiros, trazendo maior facilidade, confiabilidade e agilidade ao trabalho, bem como a informatização possibilitou o acesso dos dados e medidas dos sistemas elétricos, permitindo assim a sua aplicação em novos estudos e novas ferramentas para uso, com objetivo de torná-los mais eficientes (ALVES, 2019).

Na literatura, vários trabalhos afirmam que as variáveis climáticas têm grande impacto no comportamento da carga, a temperatura destaca-se por ser a componente mais importante

para relacionar o comportamento da demanda no curto prazo (ALTRAN, 2010; CHEMETOVA, 2018; DE ANDRADE; DA SILVA, 2016; SILVA et al. 2019).

As ferramentas para a realização da projeção da curva de carga se tornam indispensáveis a cada dia, sendo mais difundidas, pois, através delas será possível auxiliar nas atividades de operação e de planejamentos dos sistemas elétricos.

As redes neurais artificiais têm sido eficientes, e apresentam resultados satisfatórios, sendo uma das técnicas mais utilizadas para este fim, pois possui a capacidade de trabalhar com variáveis não lineares (BOU; FERREIRA, 2014; DODOMANI; SHETTY; MAGADUM, 2015; XIE et al., 2019).

A evolução tecnológica, modernização dos sistemas de medições e a implantação dos sistemas de medição de fronteiras entre as distribuidoras e supridoras facilitou o acesso dos dados de demanda e energia em tempo real. Essas medições representam o comportamento diário do consumidor, as quais tem grande influência nos resultados (KUO, et al., 2017).

A previsão de carga nos sistemas elétricos traz a oportunidade de melhorar a eficiência energética das redes, estudar o comportamento da carga, o impacto da inserção de geração distribuída e das redes inteligentes modernas “*Smart grids*”, possibilitando analisar o comportamento diário das curvas de carga (ALVES, 2019; KONG et al., 2018).

Diante desse cenário de evolução, o interesse no tema tem como intuito auxiliar as atividades diárias estratégicas das distribuidoras de energia elétrica, principalmente para fins de planejamento e tomadas de decisões, tais como, a operação do sistema elétrico, gerenciamento de carga no curto prazo e o subsídio as atividades técnicas de contratação de energia e de demanda para suprimento dos consumidores.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Esse trabalho tem como objetivo principal o desenvolvimento de uma metodologia para previsão de carga no horizonte de curto prazo.

1.2.2 Objetivos específicos

Os objetivos específicos dessa dissertação são destacados abaixo:

- a) analisar os modelos de previsão de carga recentemente publicados com objetivo de orientar e aperfeiçoar a formulação da metodologia proposta neste trabalho;
- b) levantar os dados históricos de demanda, energia e das variáveis climáticas que serão utilizadas no modelo de projeção de carga, sendo elas: energia consumida, demanda média, temperatura mínima e máxima;
- c) analisar a “causa-efeito” das variáveis climáticas mensuradas, energia e demanda;
- d) elaborar, implementar e simular o modelo computacional de previsão de carga no curto prazo;
- e) avaliar os resultados obtidos através de um estudo de caso, através do uso de dados reais de uma distribuidora de energia elétrica.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

O trabalho se encontra estruturado em 6 capítulos, incluindo esse introdutório e está organizado da seguinte forma:

O Capítulo 2 apresenta a revisão bibliográfica da literatura especializada, os principais conceitos, ferramentas e técnicas a serem tratados neste trabalho, enfatizando principalmente a previsão de carga e os modelos frequentemente utilizados e publicados nos últimos anos da literatura no horizonte de previsão de curto prazo;

O Capítulo 3 detalha as características acerca das Redes Neurais Artificiais, especificando os modelos e arquiteturas de redes existentes, modelos de algoritmos para aprendizagem da rede, funções de ativação utilizadas, métodos de validação das saídas, ainda demonstrando as principais equações matemáticas aplicadas;

O Capítulo 4 apresenta a metodologia proposta para realizar a previsão de carga no curto prazo utilizando as redes neurais artificiais através da aplicação da ferramenta desenvolvida, destacando os fatores que são influentes no comportamento da carga, detalhando os procedimentos adotados para realizar o treinamento e a simulação da RNA;

O Capítulo 5 apresenta os resultados obtidos, o desempenho do treinamento da rede, projeções das curvas de carga realizadas com dados reais de uma distribuidora de energia elétrica e o comparativo dos resultados encontrados;

E por fim, no capítulo 6 são apresentadas as conclusões e as principais contribuições do trabalho, publicações realizadas com os resultados e também algumas sugestões para o desenvolvimento de trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo compreende uma revisão bibliográfica que sintetiza os principais trabalhos sobre previsão de carga, publicados na literatura especializada nos últimos anos. O enfoque especial é dado às principais técnicas exploradas para previsão de carga no horizonte de curto prazo. Analisam-se os modelos, metodologias e técnicas aplicadas para a sua projeção, com objetivo de orientar e aperfeiçoar a formulação da metodologia proposta neste trabalho.

2.1 ESTADO DA ARTE PREVISÃO DE DEMANDA UTILIZANDO RNA

O uso da energia elétrica está em constante crescimento, por ter uma sociedade totalmente dependente desta comodidade. Essa dependência substancial do sistema elétrico de potência faz com que os sistemas elétricos de geração, transmissão e distribuição tenham frequentes investimentos em expansão e melhorias, para que atendam as cargas com segurança, qualidade e eficiência (XIE, et al., 2019).

A previsão da carga futura é de extrema importância, pois, ela impactará diretamente nas ações do planejamento, na realização das análises e nas medidas necessárias a serem tomadas para o atendimento das cargas.

Os avanços tecnológicos são decorrentes, principalmente da energia elétrica, nas atividades dos setores econômicos, quanto ao crescente consumo do setor residencial.

Com base nesta premissa, existe uma grande preocupação no acompanhamento da carga e dos fatores que impactam diretamente no seu comportamento, de forma manter o equilíbrio entre demanda e oferta, com confiabilidade e um menor custo possível.

Atualmente, o comportamento da demanda de energia elétrica é influenciado por diversos fatores, entre os mais atuantes são: os fatores climáticos, econômicos e o comportamento do uso do consumidor (BARRETO, 2017; ELJAZZAR; HEMAYED, 2016; GUIRELLI, 2006; ROMERA; MORÁN; FERNÁNDEZ, 2006).

Os fatores envolvidos no comportamento da carga trazem desafios e dificuldades no processo, mas em contrapartida auxiliam na obtenção de uma melhor solução da problemática (SALGADO, 2009; WARRIOR; SHRENIK; SONI, 2016).

Modelos computacionais de previsão de carga são ferramentas que buscam representar de modo eficaz o comportamento da carga, de forma a obter estimativas de cargas robustas e precisas. Tais estimativas permitem fazer um melhor uso dos recursos disponíveis, resultando em eficiência e segurança operacional dos sistemas de energia elétrica.

O planejamento da carga no Sistema Elétrico de Potência (SEP), além de ser uma ferramenta importante torna-se indispensável nas concessionárias do setor para realizar contratações de demanda e energia com segurança, pois essas seguem regras rígidas, com limites inferiores e superiores muito pequenos, penalizando erros maiores que essa faixa de incerteza com multas consideráveis (MILKE et al., 2017).

É essencial que sejam adotados métodos de previsões para serem utilizados como ferramentas, com a finalidade de analisar e solucionar tais problemas, e que também possam contribuir na contratação e no gerenciamento de energia e demanda (NICHIFOROV et al., 2017).

Para isto as projeções de carga são cruciais, e devem resultar em valores mais próximos possíveis da realidade, pois, através dos resultados dessas ferramentas será realizado um complexo processo de tomadas de decisões, tais como: a operação em tempo real dos sistemas e decisões de investimentos para o atendimento das necessidades para diferentes horizontes analisados (CHEN et al., 2019; DE ANDRADE; DA SILVA, 2016; MOREIRA, 2015).

Portanto, percebe-se um grande incentivo de pesquisadores e empresas, para realizar o desenvolvimento de técnicas e ferramentas mais aperfeiçoadas, visando realizar previsões mais precisas e confiáveis (BOU; FERREIRA, 2014; WERON, 2014).

2.2 MODELOS DE PREVISÃO DE CARGA

Nos últimos anos foram estudados e desenvolvidos inúmeros métodos de previsão de carga em diversos horizontes de planejamento. Na literatura especializada encontra-se uma grande quantidade de trabalhos publicados acerca do tema, e ano a ano percebe-se que as técnicas utilizadas são aperfeiçoadas e estão classificadas em 4 horizontes de previsão: longo, médio, curto e curtíssimo prazo (DE ANDRADE; DA SILVA, 2016).

Os modelos matemáticos utilizados na previsão de carga estão divididos em dois grandes grupos: métodos estatísticos e métodos baseados em inteligência artificial (GUIRELLI, 2006; REJC; PANTOS, 2011; CHEMETOVA, 2018).

Os métodos estatísticos comumente são empregados em análises de médio e longo prazo. Os principais modelos matemáticos estatísticos, são: regressão linear múltipla, ARIMA, alisamento exponencial e análise espectral. Tais modelos destacam-se pela sua eficiência para predição de fatores lineares presentes em diferentes aspectos econômicos e demográficos (GUIRELLI, 2006; REJC; PANTOS, 2011).

As técnicas baseadas em inteligência artificial ganharam mais interesse sobre as séries temporais e os métodos de regressão, os quais atualmente se encontram defasados nos quesitos de complexidade, precisão e confiabilidade nos resultados (MUZAFFAR; AFSHARI, 2019; SINGH; SINGH, K.; PALIWAL, 2016; XU; CAI; MILANOVIĆ, 2014).

Os avanços obtidos nas pesquisas através da utilização dos métodos de inteligência artificial vêm permitindo a sua aplicação em diferentes áreas do conhecimento, principalmente nas engenharias, onde comumente a presença dos fatores influentes não tem o seu comportamento linear (CHEMETOVA, 2018; DE ANDRADE; DA SILVA, 2016; KUO, et al., 2017).

Os modelos baseados em inteligência artificial vêm demonstrando resultados mais acurados em relação aos métodos tradicionais, pois conseguem desenvolver de melhor forma o processamento matemático, trazendo melhoria contínua aos métodos de previsão (LIANG; NIU; KONG, 2019; MUZAFFAR; AFSHARI, 2019; PANDEY et al., 2014).

Basicamente, o que diferencia um método do outro é a forma de analisar e manipular matematicamente os dados utilizados conforme a necessidade para a aplicação requerida.

2.2.1 Previsão de longo prazo

A previsão de carga de longo prazo trabalha com a projeção de horizontes de anos à frente, chegando até 10 a 20 anos. Esse tipo de previsão está relacionado ao planejamento e desenvolvimento de sistemas elétricos de geração, transmissão e de distribuição, apoiando o processo decisório do aumento da capacidade de atendimento ao mercado consumidor (ALTRAN, 2010; DE ANDRADE; DA SILVA, 2016).

O objetivo desta previsão é apresentar para as geradoras, transmissoras e distribuidoras de energia elétrica a evolução do consumo de energia. Com isso, é possível projetar mudanças e ampliações do sistema elétrico, construindo novas usinas e subestações, ampliações das existentes, construção de novas linhas e/ou aumentar a capacidade delas. Tais obras se tornam grandes desafios em termos de projeto, financiamento, execução e possuem grandes prazos para a maturação do empreendimento, podendo levar décadas para se tornarem produtivas (CARMONA et al., 2002; MOREIRA, 2015).

Neste tipo de previsão a relação é refletida na evolução do consumo de energia e o crescimento econômico (CARCEDO; GARCÍA, 2019).

Entre os métodos tradicionais utilizados, se tem os métodos econométricos e estatísticos, combinando uma relação entre o consumo de energia e os fatores que mais influenciam no comportamento da carga.

Neste tipo de horizonte também pode realizar a combinação da evolução do consumo, com as condições econômicas e meteorológicas (DA SILVA; SPATTI; FLAUZINO, 2016).

2.2.2 Previsão de médio prazo

A previsão de carga de médio prazo contempla um horizonte de estudo de alguns meses, até um ou dois anos à frente (DE ANDRADE; DA SILVA, 2016).

Geralmente este tipo de previsão é realizado visando auxiliar na tomada de decisões, como: suprimento de combustível, programas de manutenções, planejamento da produção, planejamento da operação de reservatórios e planejamento para contratação do suprimento de energia elétrica (compra e venda de energia), visando reduzir os riscos financeiros (ROMERA; MORÁN; FERNÁNDEZ, 2006).

A Empresa de Pesquisa Energética (EPE) destaca a importância da previsão mensal para o setor elétrico, pois, possibilita realizar uma análise dinâmica do processo do consumo de energia nas diversas classes e regiões do país, fornecendo subsídios as empresas para os estudos de planejamento e expansão do sistema (EPE, 2018).

A previsão de médio prazo é muito importante para uma distribuidora de energia elétrica, pois, atua diretamente na otimização e segurança do sistema, com ela é possível saber a futura demanda de energia, podendo assim, planejar as restrições de segurança, a otimização da alocação de máquinas geradoras, bem como o intercâmbio de energia com outras empresas de forma a garantir o suprimento de energia elétrica para o seu mercado (ALTRAN, 2010; ROMERA; MORÁN; FERNÁNDEZ, 2006).

Na literatura é possível encontrar vários trabalhos que utilizaram um modelo com base em redes neurais para previsão mensais e anuais, visando fornecer informações úteis para o planejamento e operação do sistema elétrico (ALTRAN, 2010; ROMERA; MORÁN; FERNÁNDEZ, 2006).

2.2.3 Previsão de curto prazo

O tópico de previsão de carga no horizonte de curto prazo é encontrado em maior número de trabalhos publicados em relação aos demais horizontes de previsão, é amplamente

pesquisado pela comunidade científica especializada, com a utilização de uma variedade de métodos propondo diversas soluções (SAVIOZZI; SILVESTRO, 2019).

A previsão de carga tem grande importância para a operação de sistemas elétricos de potência, visando tornar a oferta de energia estável e confiável. Com essa preocupação e o desenvolvimento tecnológico ocorreu um crescente interesse nesse horizonte (DE ANDRADE; DA SILVA, 2016; LIANG; NIU; KONG, 2019).

Na previsão de curto prazo usam-se horizontes basicamente semanais, podendo variar de alguns minutos, horas, dias ou até uma semana à frente. Seu principal papel é orientar e atuar no planejamento da operação dos sistemas elétricos. Tem impacto significativo na operação econômica da concessionária, pois, as decisões de despacho são baseadas nestas previsões, tais como, programação de despacho da geração, planejamento da manutenção de geradores, análise de confiabilidade, gerenciamento de energia ativa e reativa e previsão de demanda em sistemas de distribuição (ALTRAN, 2010).

Os métodos de previsão de curto prazo podem ser divididos em convencionais e não convencionais. Os métodos convencionais são baseados em análises matemáticas complexas, utilizando basicamente os modelos estatísticos, onde são utilizadas abordagens rígidas que não refletem as mudanças no comportamento do consumidor. Já os métodos não convencionais são baseados em técnicas de inteligência artificial que possuem a capacidade de adaptação através das experiências de alterações do ambiente, com a capacidade de aprendizado, tolerando falhas originando assim previsões aprimoradas (DE ANDRADE; DA SILVA, 2016; SAVIOZZI; SILVESTRO, 2019).

Os modelos preditivos para previsão no curto prazo empregando as técnicas de inteligência artificial, especialmente RNA se tornaram muito pesquisadas e populares (NICHIFOROV et al., 2017; XIE, et al., 2019).

Neste horizonte de projeção, os fatores climáticos, tais como, estações do ano, temperatura, sensação térmica e umidade, influenciam diretamente no comportamento da carga do sistema, outros fatores relevantes que podem ser considerados, são os fatores cíclicos, sazonais e atípicos, os quais podem trazer dificuldades para realizar a previsão (ANTUNES, 2013; DE ANDRADE; DA SILVA, 2016; GUIRELLI, 2006; LIANG; NIU; KONG, 2019).

Guirelli (2006) desenvolveu modelos de previsão de carga no curto prazo utilizando métodos de inteligência artificial para realizar a previsão de curvas de carga de 24 horas à frente com uma antecedência de 48 horas. Os modelos adotados para a previsão foram lógica Fuzzy e Redes Neurais do tipo MLP com algoritmo de aprendizado *backpropagation*. As entradas utilizadas foram: histórico de carga em períodos de 15 minutos, temperatura mínima,

temperatura máxima e energia. O modelo com RNA apresentou os melhores resultados com erros na faixa de 2%, os resultados comprovaram que a temperatura é variável exógena de maior influência no comportamento da curva de carga.

Altran (2010) visando contribuir para que o planejamento e operação dos sistemas de energia elétrica ocorram de forma segura, confiável e econômica, desenvolveu uma metodologia para previsão de carga no curto prazo (24 horas à frente) multinodal, que pode ser entendida como um sistema inteligente que considera vários pontos da rede elétrica durante a realização da previsão. O sistema desenvolvido conta com o uso de uma rede neural artificial do tipo *perceptron* multicamadas, com algoritmo de treinamento de *backpropagation*, com a função sigmoide substituída por uma função radial. O sistema desenvolvido nesta pesquisa é capaz de realizar a previsão de cargas em vários pontos do sistema de energia elétrica em muito menos tempo do que realizar a previsão de cada carga uma a uma, como se encontra em maior número na literatura. Os resultados dos sistemas desenvolvidos foram satisfatórios, apresentado um erro percentual absoluto médio (MAPE) de 1,43%, 2,93%, 3,27% e 4,35%.

Antunes (2013) apresentou um método de previsão multinodal (em vários pontos de interesse da rede elétrica) de carga elétrica de curto prazo, utilizando uma rede neural artificial baseada na arquitetura de rede de ressonância adaptativa (ART - *Adaptive Resonance Theory*), denominada de rede neural ART-ARTMAP *Fuzzy*. O método proposto foi implementado na plataforma MATLAB, onde foi possível realizar a previsão de cargas de um sistema composto por nove subestações. Como forma de avaliar os resultados obtidos pela previsão, foi calculado o erro percentual máximo da previsão e o erro percentual médio global, ficando abaixo de 2,0%. Os diferenciais do trabalho é a previsão multinodais, onde na literatura não é encontrado e a utilização da arquitetura RNA ART, pois os pesquisadores utilizam geralmente a rede neural *perceptron* multicamadas (MLP) que, via de regra, não suporta processamento que envolve muitas informações.

Pandey et al. (2014) realizaram previsão no curto prazo com RNA, visando a curva de carga do dia seguinte, utilizando dados históricos de demanda de energia de hora em hora. Os resultados foram avaliados pelo cálculo do MAPE, o qual apresentou um erro médio de 3,05% durante os testes, erro mínimo de 1,63% e o erro máximo de 6,80%.

Os autores Bou e Ferreira (2014) desenvolveram um modelo para realizar previsão de carga no horizonte curto prazo utilizando a técnica de RNA visando projetar a carga 168 horas à frente. As entradas utilizadas foram temperatura e carga, empregando 3 modelos de treinamento dos dados da rede, os modelos de treinamento testados foram: Gradiente Conjugado, *Levenberg-Marquardt* e *Bayesiano*. O programa de treinamento com Gradiente

Conjugado conseguiu uma melhor previsão, com MAPE de 3,41%; o treinamento de *Levenberg-Marquardt* teve MAPE de 3,42% e o Bayesiano 3,45%. Isso comprova que a previsão de carga horária através da técnica de Redes Neurais Artificiais pode ser considerada eficiente e confiável.

Singh, K. Singh e Paliwal, (2016) realizam a previsão de demanda no curto prazo utilizando Redes Neurais Artificiais com dados reais de 5 estados Australianos. Utilizam a técnica *feedforward* de Redes Neurais (FFNN) para realizar a previsão de perfis de consumo não lineares. Devido ao crescimento industrial em função da desregulamentação do setor elétrica na Austrália, fato que tornou o consumo de carga não linear.

Eljazzar e Hemayed (2016) realizaram previsão de carga para dados reais no Norte do Cairo através da utilização de RNA. O trabalho objetivou-se em mostrar que o comportamento da carga está diretamente aos fatores meteorológicos, localização demográfica e comportamento humano. Os autores se preocuparam em utilizar as variáveis que realmente impactam nos resultados para obter melhores resultados e evitar tempo computacional adicional. Através do modelo proposto foi possível obter os resultados com os erros diminuídos, as variáveis consideradas foram temperatura, temperatura de orvalho, vento e umidade.

Alonso e Chávez (2017) desenvolveram um modelo para previsão de carga no curto prazo utilizando RNA com a implementação de um algoritmo evolutivo (sistema imunológico artificial) para auxiliar nas soluções do algoritmo de aprendizado. Os resultados mostraram que a técnica proposta atendeu os resultados esperados com um MAPE de 4,3%.

Carvalho (2017) destaca a análise de dados provenientes de locais com níveis de consumo mais desagregados, os quais apresentam dificuldades para previsões de demanda com vários métodos devido à alta variação no consumo de energia elétrica. Apresenta-se resultados de previsões de demanda de curto prazo da energia elétrica consumida em um bloco de uma universidade por meio da rede neural de regressão generalizada (GRNN) as quais mostraram resultados muito melhores ao se comparar a outras redes testadas anteriormente no mesmo problema.

Din e Marnerides (2017) realizaram previsões de carga no curto prazo utilizando Redes Neurais Artificiais através da aplicação de dois modelos: *feedforward Deep Neural Network* (FF-DNN) e *Recurrent Deep Neural Network* (R-DNN), visando comparar o seu desempenho computacional. O método foi avaliado utilizando dados reais de 4 anos, realizando projeções para um horizonte de dias e semanas. A abordagem proposta do trabalho é realizar previsões precisas, onde é considerada crítica e necessária a centros de operações de distribuição de energia elétrica.

Dudek (2017) apresentou um conjunto de RNA utilizando regressão geral para previsão de carga no curto prazo. Vários conjuntos de cargas foram simulados, considerando taxa de aprendizagem, amostras, número de parâmetros envolvidos, visando avaliar o aprendizado da rede e dos resultados, através do cálculo de erro MAPE, o qual apresentou um erro máximo de 2,93%.

Serrano-Guerrero et al. (2017) desenvolveram um método utilizando RNA com algoritmo de aprendizado *backpropagation* e com amostras selecionadas num período de 15 em 15 minutos. As principais variáveis utilizadas foram: hora, dia da semana, mês, potência, energia, temperatura mínima e máxima e precipitação. Obteve-se um erro quadrático médio de 0,87% para projeção da curva do próximo dia.

Os autores Narayan e Hipel (2017) destacaram a importância da previsão de carga no serviço público de energia, utilizaram um modelo para previsão no curto prazo, projetando a curva de carga do dia seguinte na província de Ontário no Canadá. Utilizaram-se os dados históricos de 10 anos para o aprendizado da rede, sendo 70% dados utilizados para treinamento da rede e 30% para a sua validação. Utilizou-se uma arquitetura de memória de longo prazo, o modelo adotado possuiu um sistema robusto de previsão de carga com a capacidade de adaptar e aprender os recursos complexos envolvidos. Os resultados das simulações apresentaram erro máximo de 3,8%, 4,6% e 6,3% (NARAYAN; HIPEL, 2017).

Liu et al. (2017) utilizaram RNA utilizando memória de longa duração com arquitetura de rede recorrente visando aplicar em uma grande sequência de dados utilizados para melhorar os resultados e aplicar em redes com medições inteligentes. O modelo proposto é utilizado para prever o perfil de cargas das próximas 24 horas, o principal destaque da rede é promover resultados mais eficientes através de uma longa memória de dados. Foi realizado um comparativo da metodologia proposta com séries temporais, o qual se mostrou mais eficiente com erro de 2,13%.

A metodologia adotada por Silva et al. (2017a), utiliza RNA para realizar previsão de carga no curto prazo para os próximos 7 dias à frente, de forma horária, visando ser uma ferramenta para o planejamento da operação diária. As entradas utilizadas foram temperatura, umidade e conforto térmico de temperatura. As previsões foram aplicadas à múltiplas regiões, abrangendo 3 estados brasileiros, sendo realizada por estações do ano. Os resultados foram satisfatórios, apresentando um MAPE que variou de 0,82% a 1,66%. No modelo foi utilizado loop de treinamento com o objetivo de reduzir o erro, os autores constaram que a temperatura tem grande impacto na carga analisada.

Em outro trabalho de Silva et al., (2017b) utilizou o mesmo modelo RNA para previsão de carga de curto prazo em múltiplas regiões, para previsão horária do dia seguinte e nos próximos 7 dias, com foco na redução de erros para a previsão do primeiro dia à frente. Foram considerados padrão de curva de carga, aplicação da média ponderada nas variáveis meteorológicas, com a finalidade de determinar a variável com maior correlação em determinada estação climática do ano, para então e promover melhor desempenho no modelo. O modelo utilizou o algoritmo de treinamento *Levenberg-Marquardt* por apresentar melhor desempenho no processamento, o erro MAPE ficou abaixo de 2%.

O modelo de previsão no curto prazo desenvolvido pelos autores Singh e Sahay (2018) utilizou RNA's com arquitetura multicamadas e algoritmos de treinamento *Levenberg-Marquardt* e *Bayesiano*. A rede possui dez variáveis de entrada, sendo utilizados os dados de sete anos para treinamento da rede e dados de um ano para a validação. O trabalho mostrou a forte relação da temperatura no comportamento da carga, os resultados da simulação apresentaram a projeção de hora em hora, durante o período de um ano, apresentando o erro máximo de 1,30% e o mínimo de 0,26%.

A utilização das RNA's também foi aplicada para prever a demanda de uma indústria de manufatura em um horizonte de 30 em 30 minutos para o próximo dia. Chandramitasari, kurniawan e Fujimura (2018) utilizaram dados de um dia para o treinamento da rede, qual apresentou um erro de 2,51%.

Yahya, Hadi e Putranto (2018) realizam um estudo de caso utilizando RNA de arquitetura de rede recorrente. Os dados foram selecionados por dia da semana, o treinamento da rede é realizado sempre com dados do mesmo dia a ser projetado. Foram utilizados dados de 8 semanas para treinamento, dados de uma semana para testes e de uma semana para a simulação. Os algoritmos de treinamento utilizados na rede foram o *Levenberg-Marquardt* o qual apresentou um erro de 1,60% e o *Bayesiano*, o qual apresentou um erro de 1,47% (YAHYA; HADI; PUTRANTO, 2018).

Muzaffar e Afshari (2018) utilizaram redes neurais recorrentes (RNN), com memória de curto prazo, a qual se mostrou mais eficiente em relação aos métodos tradicionais. As variáveis de entrada consideradas formam: temperatura, umidade e velocidade do vento. A rede foi treinada e utilizada para realizar a previsão em horizontes de 24 horas, 48 horas, 7 dias e 30 dias à frente. Os métodos utilizados foram ARMA, SARIMA, ARMAX e LSTM – *Long Short-term Memory*. O modelo LSTM apresentou o menor erro nas simulações com o valor de MAPE de 1,52%.

Nigitz e Gölles (2019) desenvolveram um método adaptativo de previsão de carga no curto prazo, a técnica é baseada em modelos de regressão e correlação linear. Projetou-se a curva de carga de 24 horas à frente considerando de entrada dados históricos de demanda e temperatura, o erro médio calculado foi de 2,90%. O modelo desenvolvido é adaptável e adequado para utilização em sistemas de gerenciamento de energia visando a operação eficiente em sistemas híbridos de energia.

Atualmente a previsão de carga no curto prazo se tornou ainda mais importante, devido ao fato da desregulamentação dos setores de energia e a agregação e integração dos recursos renováveis. O modelo híbrido desenvolvido por Liang, Niu e Hong (2019) combinaram RNA com outras técnicas para projetar uma curva de carga de 24 horas à frente, os dados simulados foram validados com dados reais obtidos de hora em hora e comparados com as outras técnicas combinadas.

Com o mesmo objetivo, Bento et al. (2019) realizam previsão de carga no curto prazo utilizando modelo híbrido aprimorado utilizando RNA, para projetar a curva de carga de 24 horas à frente, utilizando um algoritmo de aprendizado combinado visando melhorar o aprendizado da rede e reduzir o tempo de esforço computacional. A metodologia foi testada através de um estudo de caso utilizando dados reais *New England* e *New York*, o maior MAPE dos resultados foi de 3,55%.

Os autores Carcedo e García (2019) desenvolveram um método de previsão de carga no curto prazo considerando os efeitos da temperatura e da luz do dia ao longo das horas do dia. O modelo mostrou a alta sensibilidade da temperatura com a demanda, principalmente quando a sociedade está em modo “ativo” ao longo do dia. Concluíram também que a luz dia impacta na carga do sistema, pois o movimento de rotação e translação afeta no ciclo de insolação.

Silva et al. (2019) aplicou um método baseado em RNA com o objetivo de apresentar um fluxograma metodológico de reconhecimento de padrões de variáveis meteorológicas. Para tanto, as saídas para o usuário são os gráficos de dispersão entre variáveis meteorológicas e a demanda, a melhor variável meteorológica a ser empregada no modelo, o índice *Mutual Information*, que estima a relação não linear entre as variáveis, e o índice de correlação, que apresenta a relação linear. Com base nesse resultado, é escolhida a variável a ser empregada no modelo de previsão de carga.

Saviozzi e Silvestro (2019) apresentaram um modelo utilizando RNA com duas funcionalidades, modelagem e previsão da carga no curto prazo. A modelagem da carga de subestações monitoras através da entrada de dados de um sistema SCADA, as informações são selecionadas para então projetar a curva de carga do próximo dia em intervalos de 15 minutos.

Três redes RNA foram desenvolvidas, para cada tipo de dia da semana, sendo os resultados avaliados através do cálculo do MAPE. Os erros mínimos encontrados são 5,05% para dias de semana, erro de 5,08% para pré-feriados e 7,09% para dias de semana.

Kong et al. (2018) desenvolveram um modelo para previsão de carga residenciais, com uma estrutura de aprendizagem profunda com redes neurais recorrentes considerando memória de curto prazo. O modelo constatou que comportamento da carga é volátil e está diretamente relacionada ao comportamento do consumidor e as variáveis climáticas.

Chen et al. (2019) desenvolveram um método utilizando RNA residuais profundas para a previsão de um horizonte de 24 horas. Foi realizado uma alteração no algoritmo de aprendizagem visando otimizar os dados para treinamento. Os resultados são comparados com simulações realizadas com Monte Carlo, onde se mostrou superior na precisão e robustez e à variação de temperatura.

Alves (2019) utilizou uma metodologia com rede neural ARTMAP *Fuzzy* e uma metodologia híbrida entre a rede neural ARTMAP *Fuzzy* e o Método dos Mínimos Quadrados para realizar a previsão de cargas elétricas não residenciais mistas em curto prazo utilizando dados de demanda de cargas de uma universidade brasileira. Para solucionar o problema, foram introduzidas os de valores de cargas máxima, mínima e média referentes à cada intervalo de tempo e dia da semana com o objetivo de suprir a pouca variabilidade de entradas. Depois de observado o comportamento da rede neural ARTMAP *Fuzzy* neste cenário foi desenvolvido uma metodologia híbrida entre a rede neural ARTMAP *Fuzzy* e o método dos mínimos quadrados, denominada rede neural ARTMAP *Fuzzy* – MMQ o qual apresentou os melhores resultados.

2.2.4 Previsão de curtíssimo prazo

As previsões de demanda no curtíssimo prazo possuem um horizonte de projeção de poucos segundos até pouco menos de uma hora, que praticamente exprimem o perfil instantâneo da carga (ALTRAN, 2010; DE ANDRADE; DA SILVA, 2016).

É utilizada essencialmente para o planejamento e controle dos sistemas elétricos de potência, buscando o gerenciamento efetivo da carga, permitindo o desenvolvimento de estratégias de controle, procedimentos de manutenção, otimização de sistemas, subsidio aos processos de relocação de manutenções de unidades geradoras, partidas de unidades térmicas, gerenciamento da demanda no horário de ponta, intercâmbio de energia entre empresas e análise

de contingências em tempo real (ALTRAN, 2010; CASAGRANDE et al., 2014; CHEMETOVA, 2018).

Usado mais recentemente para o desenvolvimento de controles automáticos (CGA) mais eficientes, com a finalidade de manter a sintonia entre a demanda e o fornecimento de eletricidade (DE ANDRADE; DA SILVA, 2016).

Ao longo da pesquisa percebeu-se que os métodos de previsão de demanda de energia elétrica em curtíssimo prazo não são muito numerosos (NEUSSER, 2015).

2.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

O presente capítulo introduziu o assunto de previsão de carga, detalhando os seus horizontes de previsão, procedimentos utilizados, suas principais aplicações, enfatizando as principais técnicas baseadas em inteligência artificial.

Abordou ainda, uma profunda revisão bibliográfica da previsão de carga no curto prazo, demonstrando sua aplicação, os modelos e técnicas utilizadas, suas metodologias, os resultados dos trabalhos mais relevantes e recentemente publicados na literatura especializada.

A Tabela 1 apresenta de forma resumida os trabalhos descritos na revisão bibliográfica, destacando os autores que realizaram previsão de carga utilizando curvas de cargas com a demanda integralizada em período de 15 minutos e 60 minutos, ainda, os autores que enfatizaram e comprovaram que as variáveis climáticas têm forte impacto no comportamento da carga.

Tabela 1 – Resumo revisão bibliográfica

(continuação)

Descrição do trabalho	Autores
Previsão com curva de carga integralizada em períodos de 15 minutos	Guirelli (2006) Bou e Ferreira (2014) Singh, K. Singh e Paliwal (2016) Eljazzar e Hemayed (2016) Alonso e Chávez (2017) Carvalho (2017) Din e Marnerides (2017) Dudek (2017) Serrano-Guerrero et al. (2017) Narayan e Hipel (2017) Liu et al. (2017) Silva et al. (2017a)

Tabela 1– Resumo revisão bibliográfica

(conclusão)

Descrição do trabalho	Autores
Previsão com curva de carga integralizada em períodos de 15 minutos	Singh e Sahay (2018) Yahya, Hadi e Putranto (2018)
Previsão com curva de carga integralizada em períodos de 60 minutos	Pandey et al. (2014) Liang, Niu e Hong (2019)
Influência das variáveis climáticas no comportamento da carga	Eljazzar e Hemayed (2016) Silva et al. (2017a) Silva et al. (2017b) Silva et al. (2019) Singh e Sahay (2018) Muzaffar e Afshari (2018) Carcedo e García (2019) Chen et al. (2019) Kong et al. (2019)

Fonte: Próprio autor

3 REDES NEURAIS ARTIFICIAIS

3.1 INTRODUÇÃO

Os primeiros trabalhos e técnicas utilizando RNA surgiram há mais de 50 anos, mas somente em 1990 começou a ser fortemente pesquisado e utilizado em várias áreas, tendo ainda um potencial imenso (DA SILVA; SPATTI; FLAUZINO, 2016; XIE et al., 2019).

Inicialmente estudos e conceitos formais sobre as RNA surgiram na década de 40, sendo a primeira publicação relacionada à neurocomputação no ano 1943 pelos autores McCulloch e Pitts (1943), que propuseram o primeiro modelo de neurônio artificial, onde faziam uma analogia entre células vivas e o processo eletrônico, simulando o comportamento de um neurônio artificial.

Nos anos seguintes, outros pesquisadores publicaram sobre as RNA, mas, somente nas décadas 70 e de 80 que ocorreu um grande impulsionamento nas pesquisas (ALTRAN, 2010; XIE et al., 2019).

Nos anos 80 com o desenvolvimento dos computadores com maior capacidade de processamento, ocorreu o desenvolvimento de algoritmos mais eficientes e robustos e conseqüentemente foi possível realizar novas descobertas sobre as RNA (DA SILVA; SPATTI; FLAUZINO, 2016).

A maior contribuição nessa fase foi o desenvolvimento do algoritmo backpropagation, proposto por Werbos (1974), e redescoberto por Rumelhart, Hilton e Williams (1986), onde os autores desenvolveram um algoritmo que permitia ajustar os pesos em uma rede com mais de uma camada, a proposição deste algoritmo reascendeu e motivou as pesquisas em redes neurais artificiais (DA SILVA; SPATTI; FLAUZINO, 2016).

É possível encontrar com facilidade as RNA empregadas em diversos problemas relacionados às engenharias e ciências. Dentre suas potencialidades, podemos destacar as seguintes aplicações: aproximador universal de funções, controle de processos, reconhecimento/classificação de padrões, agrupamento de dados (clusterização), sistemas de previsão, otimização de sistemas, memórias associativas, entre outros (DA SILVA; SPATTI; FLAUZINO, 2016).

As características mais relevantes envolvidas com aplicações de redes neurais artificiais são: não linearidade, adaptação por experiência, capacidade de aprendizado, habilidade de generalização, organização de dados, tolerância a falhas, armazenamento distribuído e facilidade de prototipagem (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

As redes neurais artificiais são ferramentas que podem ser aplicadas em diversos tipos de problemas, as principais características se destaca a sua habilidade em mapear sistemas não lineares, aprendendo o comportamento a partir de informações das variáveis de entrada (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001; XIE, et al., 2019).

Dentro das potenciais áreas de aplicação das redes neurais artificiais, mencionam-se sistemas de previsão, cujo objetivo consiste em estimar valores futuros de um processo, devido a sua capacidade de aprendizado e generalização, o que torna a técnica utilizada capaz de realizar a aproximação de funções não lineares e a previsão de séries temporais (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Além dessas aplicações, as potencialidades das RNA permitem a resolução de outros tipos de problemas advindos das mais diferentes áreas do conhecimento, os métodos são selecionados de acordo com o tipo de problema apresentado conforme pesquisa realizada em diversos artigos e periódicos científicos mais relevantes nos últimos anos.

3.2 CONCEITOS INICIAIS

As redes neurais artificiais são modelos computacionais inspirados no funcionamento dos sistemas nervosos biológicos e do próprio cérebro humano, basicamente, são modelos matemáticos inspirados na simplificação do funcionamento dos neurônios biológicos, com a capacidade de aprendizado a partir da experiência com as entradas do sistema (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Elas possuem a capacidade de obtenção e manutenção das informações, podendo ser definidas como um conjunto de unidade de processamento, e são caracterizadas por neurônios artificiais, os quais estão interligados por muitas interconexões, chamadas sinapses artificiais, e podem ser representadas por vetores e/ou matrizes de pesos sinápticos (DA SILVA; SPATTI; FLAUZINO, 2016).

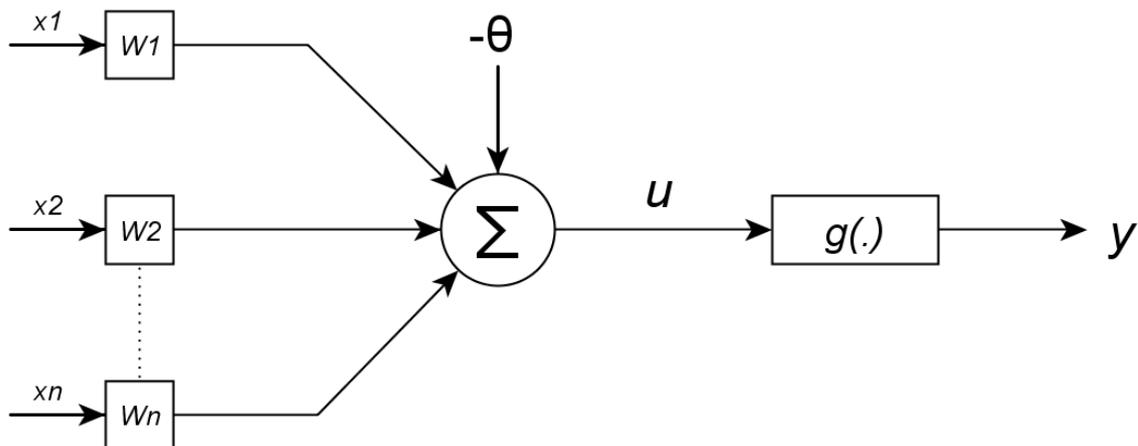
O modelo de neurônio mais simples proposto por McCulloch e Pitts (1943), utiliza processamento paralelo e alta conectividade, distribuído através de suas unidades de processamento, assim, os neurônios que por sua vez são favoráveis ao armazenamento de conhecimento, são disponibilizados para uma posterior utilização. São semelhantes ao cérebro devido à duas principais características: conhecimento adquirido por um processo de aprendizagem, conexões entre seus neurônios utilizadas para armazenar o conhecimento adquirido (DA SILVA; SPATTI; FLAUZINO, 2016).

Uma rede neural possuiu alto poder de generalizar informações após uma fase de aprendizagem, possibilitando capturar relações funcionais entre os dados produzindo uma saída próxima daquela esperada (DA SILVA; SPATTI; FLAUZINO, 2016; FERNADES, 2009).

A generalização da rede neural ocorre para produzir várias saídas adequadas para as entradas que não estavam presentes durante o treinamento da rede, possibilitando assim a solução do problema (HAYKIN, 2001).

A modelagem deste tipo de sistema pode ser descrita como demonstrado na Figura 1 e nas equações (1) e (2).

Figura 1 – Neurônio artificial



Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

A Figura 1 representa os principais parâmetros que constituem a estrutura de uma RNA, o qual funciona a partir de sete elementos básicos conforme DA SILVA; SPATTI; FLAUZINO (2016), sendo:

- sinais de entrada (x_1, x_2, x_n): representam valores assumidos pelas variáveis, podem ser sinais ou medidas advindas do meio externo;
- pesos sinápticos (w_1, w_2, w_n): valores que servirão para ponderar cada um dos sinais de entrada;
- combinador linear (Σ): tem a função de agregar todos os sinais de entrada após a ponderação realizada pelos pesos sinápticos, gerando um valor de potencial de ativação;

- d) limiar de ativação (θ): variável que exprime o resultado produzido pelo combinador linear, para que ele possa gerar um valor de disparo em relação à saída do neurônio;
- e) potencial de ativação (u): resultado obtido pela diferença do valor produzido entre o combinador linear e o limiar de ativação;
- f) função de ativação (g): restringe-se a limitar o intervalo de amplitude do sinal de saída para valores razoáveis finitos;
- g) sinal de saída (y): valor final produzido.

As equações (1) e (2) resumem o resultado produzido pelo neurônio artificial proposto por McCulloch e Pitts (1943):

$$u = \sum_{i=1}^n w_i \times X_i - \theta \quad (1)$$

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

A função de ativação de cada neurônio é essencial, em cada camada, para um sistema eficiente e robusto. Trata-se de uma função matemática aplicada à combinação linear entre as variáveis de entradas e pesos, para determinar a relação entre entradas e saídas de cada neurônio da rede (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

3.2.1 Funções de ativação

A função de ativação de uma RNA tem por finalidade fornecer uma saída similar a saída de um neurônio, o qual não é linearmente dependente de suas entradas, restringindo a amplitude de saída do neurônio (ALTRAN, 2010).

Na literatura as principais funções de ativações são classificadas em dois grandes grupos: funções de ativação parcialmente diferenciáveis e funções de ativação totalmente diferenciáveis. As funções de ativação parcialmente diferenciáveis possuem pontos cujas derivadas de primeira ordem são inexistentes, tendo as principais funções: degrau, degrau bipolar e rampa simétrica. Já as funções de ativação totalmente diferenciáveis são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio e definição, tendo quatro funções principais: função logística, função tangente hiperbólica, função gaussiana e função linear (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

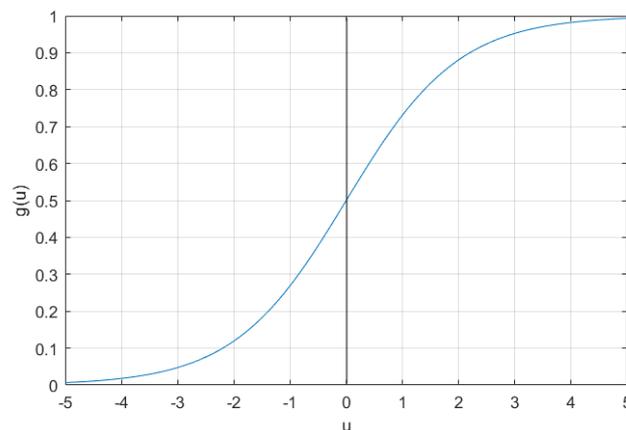
3.2.1.1 Função logística

A origem deste tipo de função está vinculada à preocupação em limitar o intervalo de variação da derivada da função, pela inclusão de um efeito de saturação. Sua derivada também é uma função contínua. Os valores produzidos sempre serão entre zero e um, e a expressão matemática é dada pela equação (3) (DA SILVA; SPATTI; FLAUZINO, 2016):

$$g(u) = \frac{1}{1 + e^{-\beta \cdot u}} \quad (3)$$

Onde β é uma constante real associada ao nível de inclinação da função, frente ao seu ponto de inflexão. A representação gráfica da função logística é ilustrada na Figura 2.

Figura 2 – Gráfico da função logística



Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

3.2.1.2 Função tangente hiperbólica

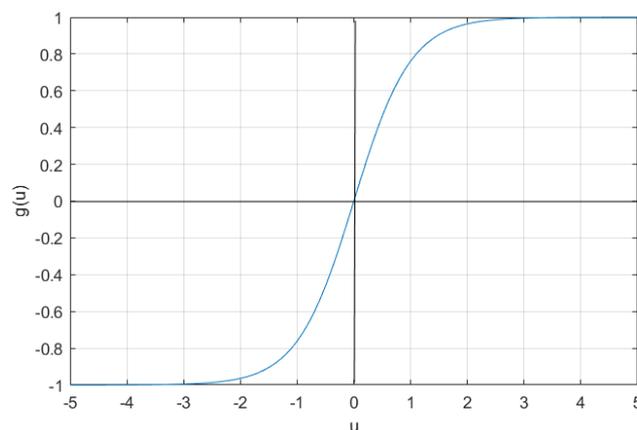
Pelo fato da função logística apresentar valores de ativação apenas no intervalo (0, 1), em muitos casos ela é substituída pela função tangente hiperbólica, que preserva a forma sigmoide da função logística, o resultado de saída assume valores reais entre -1 e 1, cuja expressão matemática é definida pela equação (4) (DA SILVA; SPATTI; FLAUZINO, 2016):

$$g(u) = \frac{1 - e^{-\beta \cdot u}}{1 + e^{-\beta \cdot u}} \quad (4)$$

A função logística e a tangente hiperbólica pertencem à família das funções denominada sigmoidais. A função tangente hiperbólica é a função que melhor se aproxima da função do neurônio biológico (DA SILVA; SPATTI; FLAUZINO, 2016).

Além disso, possui um modelo matemático simples, comparado a outros métodos de ativação, sendo aplicada na maioria dos estudos de caso (XU; CAI; MILANOVI, 2014). A representação gráfica da função tangente hiperbólica é ilustrada na Figura 3.

Figura 3 – Gráfico da função tangente hiperbólica



Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

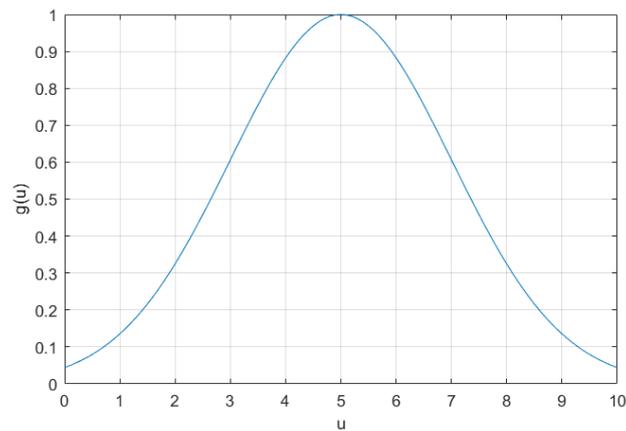
3.2.1.3 Função gaussiana

A sua saída produzirá resultados iguais para aqueles de potencial de ativação que estejam posicionados a uma mesma distância de seu centro, cuja expressão matemática é definida pela equação (5) (DA SILVA; SPATTI; FLAUZINO, 2016):

$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (5)$$

Onde c é um parâmetro que define o centro da função gaussiana e σ denota o desvio padrão associado à mesma. A representação gráfica da função logística é ilustrada na Figura 4.

Figura 4 – Gráfico da função gaussiana



Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

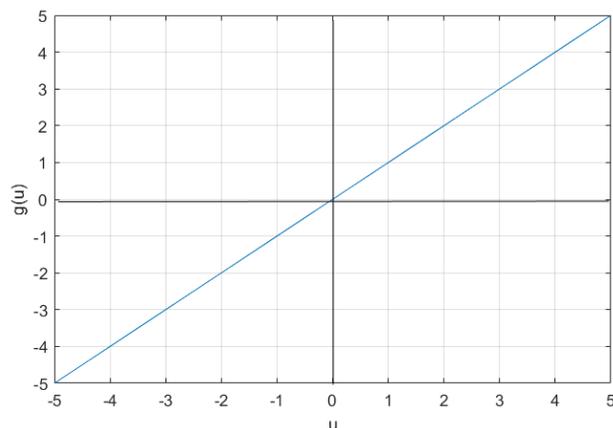
3.2.1.4 Função linear

A saída da função linear produz resultados idênticos aos valores do potencial de ativação, sendo a sua expressão matemática definida pela equação (6) (DA SILVA; SPATTI; FLAUZINO, 2016):

$$g(u) = u \quad (6)$$

A representação gráfica da função linear é ilustrada na Figura 5.

Figura 5 – Gráfico da função linear



Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

Esta função de ativação é utilizada como aproximador universal de funções para mapear o comportamento entre as variáveis de entrada e saída de processos. Geralmente também é utilizada nas camadas de saída em redes neurais de regressão (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

3.2.2 Arquiteturas das RNA

Basicamente, uma RNA pode ser dividida em três partes: camada de entrada, camadas escondidas (intermediárias, ocultas ou invisíveis) e camada de saída. A camada de entrada é responsável pelo recebimento dos dados de amostras ou padrões para o sistema, a camada escondida, aonde quase todo processamento da rede é realizado tem a função de extrair as características associadas da camada de entrada e do processo a ser inferido e a camada de saída é responsável pela apresentação dos resultados da rede (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Todas as conexões, entre as camadas, possuem um peso que determina sua contribuição na decisão do disparo, possibilitando controlar os estímulos dos neurônios, este conjunto de fenômenos é denominado arquitetura da rede neural (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

As principais arquiteturas de redes neurais artificiais são: redes *feedforward* (alimentação à frente) de camada simples, redes *feedforward* de camadas múltiplas, redes recorrentes e redes reticuladas (DA SILVA; SPATTI; FLAUZINO, 2016).

As redes recorrentes (*feedback*) possuem realimentação entre sua saída e entrada, possuindo assim um ciclo na conectividade das redes. As redes não-recorrentes (*feedforward*) não possuem laços de realimentação, cada neurônio recebe sinais somente das camadas anteriores, não possuem memória, e a sua saída é determinada em função da entrada e dos valores dos pesos sinápticos (ALTRAN, 2010).

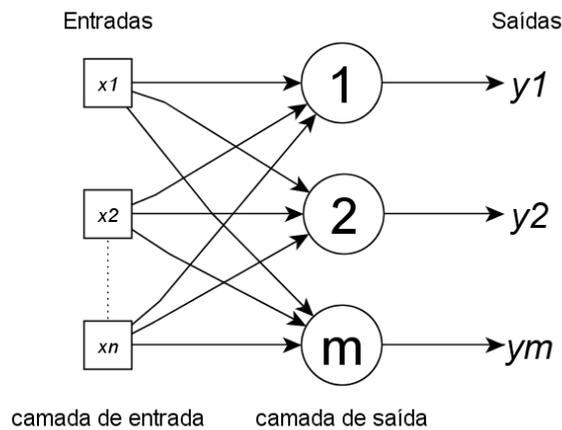
O alcance de resoluções para problemas pela rede está correlacionado diretamente com a arquitetura adotada.

3.2.2.1 Arquitetura *feedforward* de camada simples

A arquitetura de rede *feedforward* apresenta apenas uma camada e uma única camada de neurônios, a qual é a própria saída. O fluxo das informações é unidirecional, da camada de

entrada em direção a camada de saída, conforme pode ser visualizado na Figura 6 (DA SILVA; SPATTI; FLAUZINO, 2016).

Figura 6 – Rede *Perceptron* de camada simples



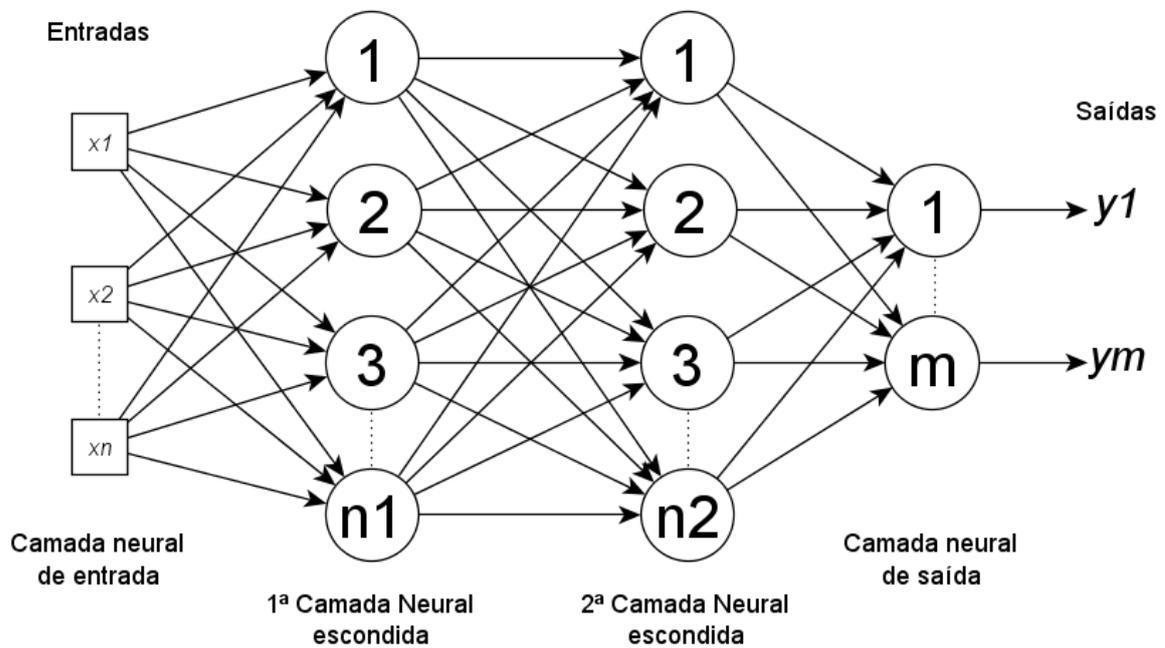
Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

Percebe-se através da Figura 6 que a quantidade de saídas sempre coincidirá com o número de neurônios.

3.2.2.2 Arquitetura *feedforward* de camadas múltiplas

Na arquitetura *feedforward* de camadas múltiplas há presente uma camada escondida de neurônios entre a camada de entrada e saída. Na Figura 7 pode ser visualizado que a quantidade de neurônios que compõem a primeira camada escondida é diferente do número de sinais que compõem a camada de entrada da rede (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Figura 7 – Rede *Perceptron* de múltiplas camadas



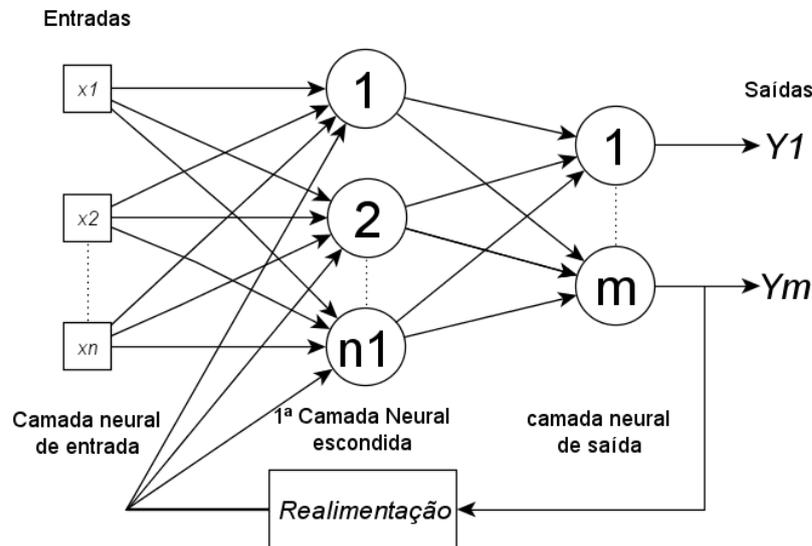
Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

A complexidade do problema a ser solucionado pela rede é que determinará a quantidade do número de camadas escondidas e os seus respectivos neurônios. A quantidade de sinais de saída sempre coincidirá com o número de neurônios da respectiva camada.

3.2.2.3 Arquitetura recorrente ou realimentada

Na arquitetura recorrente as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios, possuindo assim, um processamento dinâmico das informações, conforme apresentado na Figura 8 (ALTRAN, 2010; DA SILVA; SPATTI; FLAUZINO, 2016).

Figura 8 – Rede *Perceptron* realimentada



Fonte: Adaptado de DA SILVA; SPATTI; FLAUZINO (2016)

Com o processo de realimentação as saídas produzidas levam em consideração os valores recebidos das saídas anteriores.

3.2.3 Rede RNA com arquitetura de rede perceptron

A arquitetura de rede neural perceptron possui simplicidade em sua configuração e no seu princípio de funcionamento, constitui-se de uma camada neural com apenas um neurônio. A perceptron pertence à arquitetura de rede *feedforward* de camada única, pois seu fluxo de informações é unidirecional (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

As entradas são inicialmente ponderadas pelos pesos sinápticos a fim de quantificar a sua importância, conforme o valor atribuído ao neurônio, com a finalidade de mapear o comportamento da entrada e da saída do processo (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

O valor resultante da decomposição de todas as entradas após a ponderação dos pesos, é adicionado o limiar de ativação sendo este repassado a função de ativação cujo resultado será a saída produzida (DA SILVA; SPATTI; FLAUZINO, 2016).

3.2.3.1 Arquitetura de redes perceptron multicamadas

As redes neurais Perceptron de múltiplas camadas (MLP) são uma importante classe de redes neurais e também uma das mais versáteis quanto à aplicabilidade, pois podem ser aplicadas em diversos tipos de problemas. São caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, possuindo no mínimo duas camadas de neurônios (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

A MLP constitui-se de um conjunto de nós, divididos em camadas de entrada, camadas escondidas e camadas de saídas. Um aspecto fundamental neste tipo de rede é determinar o número de camadas escondidas, o número de neurônios em cada uma das camadas ocultas e a especificação dos seus pesos sinápticos. A habilidade de aprender através de seu treinamento, resulta em um grande poder computacional (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Na arquitetura de rede MLP cada camada tem uma função específica funcionando da seguinte forma: os sinais da camada de entrada enviam estímulos para a camada de saída a qual irá automaticamente reformular a saída, em seguida os neurônios pertencentes às camadas intermediárias extraem a maior parte das características e informações da camada de entrada a qual são codificadas em seus pesos sinápticos e limiares visando deixar a rede mais representativa para a resolução de um determinado problema, enfim os neurônios da camada de saída recebem os sinais vindos da última camada intermediária e produz uma resposta padrão que será a saída da rede neural (ALTRAN, 2010; DA SILVA; SPATTI; FLAUZINO, 2016).

Este tipo de rede caracteriza-se por ser *feedforward* de múltiplas camadas, que como mencionado anteriormente, as saídas dos neurônios se conectam unicamente às entradas dos neurônios da camada seguinte, sem a necessidade de laços de realimentação (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

A conexão entre os neurônios da rede acontece por meio dos ajustes de pesos, assim, todo o conhecimento obtido pelo processamento dos neurônios da camada intermediária será armazenado nos próprios pesos, sendo realizado dentro do processo de treinamento supervisionado, o algoritmo de aprendizado nesta arquitetura de rede é denominado do *backpropagation* ou algoritmo de retropropagação do erro (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

3.3 TREINAMENTO DA RNA

A habilidade de aprendizado e generalização das informações de uma rede neural artificial é um dos seus destaques mais relevantes, sendo possível solucionar problemas complexos e muitas vezes intratáveis. A rede possui a capacidade de aprendizado através das amostras ou padrões de entrada, os quais exprimem o comportamento do sistema (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

O processo de treinamento da rede consiste na aplicação das etapas ordenadas necessárias para que ocorra a sintonização dos pesos sinápticos e limiares de seus neurônios, visando a produção da generalização de soluções pelas suas saídas, possibilitando a produção de uma saída adequada, assim produzindo a solução do problema (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

O objetivo do treinamento ou aprendizagem, é tornar a aplicação de um conjunto de entradas (vetores) em um conjunto de saídas desejadas. O conjunto ordenado das etapas visando o treinamento da rede é denominado de algoritmo de aprendizagem (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

As amostras de entrada geralmente são divididas em dois subconjuntos: treinamento e teste. O subconjunto de treinamento é composto por aproximadamente 60% a 90% das amostras, as quais são utilizadas para realizar o aprendizado da rede. Já o subconjunto de testes utilizará o restante das amostras para verificar se as generalizações das soluções pela rede já estão em patamares aceitáveis para a saída (DA SILVA; SPATTI; FLAUZINO, 2016).

O ajuste dos pesos sinápticos e limiares de seus neurônios será denominada de época de treinamento (DA SILVA; SPATTI; FLAUZINO, 2016).

A forma como a rede se relaciona com o ambiente, advém do tipo de aprendizado; classificado em aprendizado supervisionado e não-supervisionado.

3.3.1 Treinamento supervisionado

A estratégia de treinamento supervisionado consiste em a rede aprender através da combinação dos padrões de entrada e saída, como se houvesse um “professor” ensinando para a rede qual a resposta correta para cada amostra apresentada em suas entradas, tendo assim o comportamento da rede de acordo com os padrões de entrada (ALTRAN, 2010).

Um conjunto de entrada é apresentado à rede e a saída correspondente, através desta ação comparativa é calculado o correspondente vetor de saída desejado. O erro é propagado

através da rede e os pesos são continuamente ajustados pelo próprio algoritmo de aprendizagem na tentativa de minimizar a defasagem entre as respostas produzidas. Este tipo de aprendizagem proporciona informações de erro e de desempenho da rede, assim ela será considerada treinada quando as defasagens dos valores estiverem dentro de valores aceitáveis (HAYKIN, 2001).

3.3.2 Treinamento não supervisionado

No procedimento de treinamento não supervisionado, inexistem as respectivas saídas desejadas para a rede, e ela própria deverá se auto organizar em suas particularidades existentes que contenham similaridades, extraindo assim suas propriedades estatísticas do conjunto de treinamento sem a possibilidade de avaliar seu desempenho. O treinamento da rede utiliza apenas o seu conjunto de amostras de entrada (HAYKIN, 2001).

3.3.3 Algoritmo de treinamento

Vários algoritmos podem ser utilizados para o treinamento da rede. Dentre os principais utilizados destacam-se: *Backpropagation*, *Levenberg-Marquardt* e Bayesiano.

O algoritmo *backpropagation* é o mais utilizado para treinamento de redes neurais estruturadas em camadas, consiste em um método de descida no gradiente da função erro quadrático a fim de minimizá-lo. É realizado mediante as aplicações sucessivas de duas fases: fase *forward* e fase *backward*.

A primeira fase *forward* ou propagação adiante, os sinais advindos da entrada são propagados camada a camada até a produção das saídas, obtendo a resposta da rede, levando em consideração os pesos sinápticos e limiares dos neurônios, os quais permaneceram inalterados durante cada execução desta fase (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Antes de iniciar a segunda fase, o algoritmo de aprendizagem supervisionada realizará a comparação das saídas produzidas da primeira fase com as respectivas respostas desejadas, calculando o erro (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Na segunda fase *backward* “propagação reversa” será realizado os ajustes dos pesos sinápticos e limiares de todos os neurônios na tentativa de diminuir o erro e produzir uma saída mais próxima a desejada (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

O algoritmo ajusta os valores das matrizes de pesos em direção oposta do gradiente da função de erro quadrático. Para medir o desempenho dos resultados produzidos pelos neurônios

de saída, conforme a função que representa do erro de aproximação, definido pela equação (7) (DA SILVA; SPATTI; FLAUZINO, 2016):

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (7)$$

Onde:

$Y_j^{(3)}(k)$ é o valor produzido pelo neurônio de saída;

$d_j(k)$ é o valor desejado.

O desempenho global do algoritmo *backpropagation* pode ser calculado pelo erro quadrático médio, definido pela equação (8) (DA SILVA; SPATTI; FLAUZINO, 2016):

$$E_M = \frac{1}{p} \sum_{k=1}^p (E(k)) \quad (8)$$

Onde:

$E(k)$ é o erro quadrático obtido.

Este algoritmo na prática pode convergir muito lentamente, visando solucionar este inconveniente e diminuir o esforço computacional, algoritmos de otimização são aplicados em conjunto com o algoritmo *backpropagation* (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

Já o algoritmo *Levenberg-Marquardt* é considerado o método mais rápido para treinamento de redes *feedforward perceptron*, é implementado no algoritmo *backpropagation* (DA SILVA; SPATTI; FLAUZINO, 2016; DE MACEDO, 2014).

O algoritmo *Levenberg-Marquardt* consiste em uma aproximação do método de Newton, para utilizar sua rápida convergência visando reduzir os erros de convergência. Consiste, basicamente em encontrar o mínimo global na função erro usando um método iterativo (DE MACEDO, 2014).

É um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não lineares. A característica principal deste algoritmo é a implementação da matriz jacobiana, onde passa a ser reescrita em função das matrizes sinápticas da rede (DA SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001).

A regra para aprendizagem é baseada no ajuste dos pesos do MLP, está fundamentada em uma matriz jacobiana que relaciona a evolução do erro em da iteração entre aos pesos sinápticos e limiares, convergindo os valores rapidamente ao erro mínimo global (SILVA, 2017a). Sendo definido pela equação (9) (DA SILVA; SPATTI; FLAUZINO, 2016):

$$\Delta W = (J^T(W) \times J(W) + \mu \times I)^{-1} \times J^T(W) \times E \quad (9)$$

Onde:

$J(W)$ são as matrizes jacobianas obtidas nas etapas de *forward* e *backward*;

E é a matriz identidade;

μ é a taxa de convergência do algoritmo de *Levenberg-Marquardt*.

A taxa de convergência funciona como um fator de estabilização do treinamento, ajustando a aproximação de forma a utilizar a rápida convergência que é método de Newton evitando passos muito grandes que possam ocasionar possíveis erros na convergência (KOHLENER, 2013).

Quando incorporado ao algoritmo *backpropagation* ele resulta em uma potencialização e aceleração do processo de treinamento de 10 a 100 vezes mais rápido que o algoritmo *backpropagation* convencional (DA SILVA; SPATTI; FLAUZINO, 2016).

Esse algoritmo é muito utilizado em trabalhos técnicos sempre que se deseja ajustar um modelo a um conjunto de dados experimentais. Possui a característica de adquirir convergência com menos iterações, entretanto, necessita mais cálculos por iteração devido aos cálculos das matrizes inversas, exigindo um grande esforço computacional (DA SILVA; SPATTI; FLAUZINO, 2016).

Tal método é considerado o mais rápido e eficiente para trabalhar com amostras moderadas de parâmetros, porém quando esse número é elevado, a utilização desse algoritmo não é adequada, pois tornará o processo de treinamento muito lento (KOHLENER, 2013; DA SILVA; SPATTI; FLAUZINO, 2016).

3.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo abordou-se sobre as redes neurais artificiais, primeiras técnicas e conceitos aplicados, primeiros autores e primeiras descobertas. Apresenta-se os conceitos iniciais, detalhamento do modelo de neurônio artificial e a sua representação matemática. Foram também apresentadas as principais arquiteturas, tipos de redes, funções de ativação e o processo de aprendizagem da RNA.

Essencialmente, apresentaram-se as suas principais características, habilidades e vantagens, destacando também suas fundamentais aplicações.

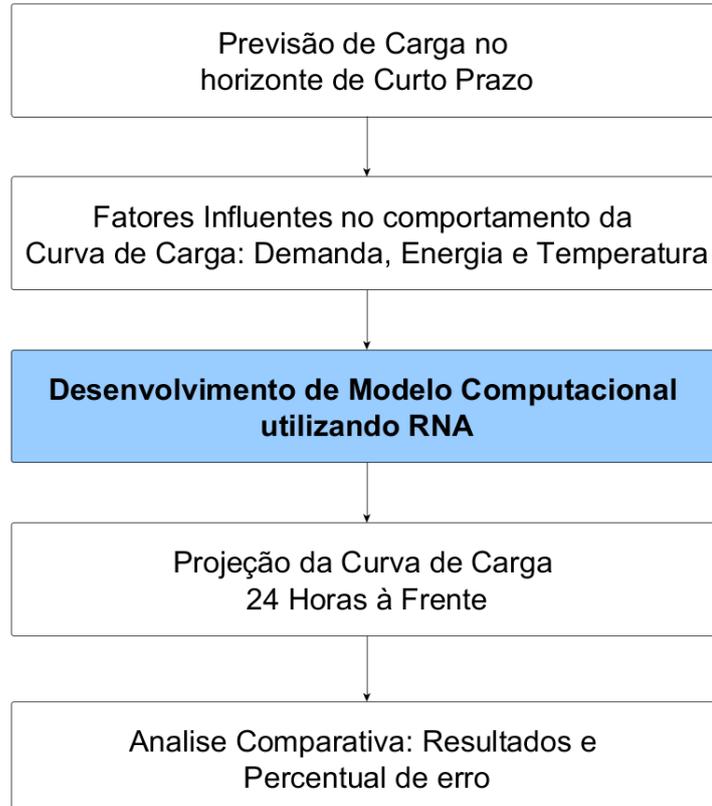
4 METODOLOGIA UTILIZANDO REDES NEURAIIS NA PREVISÃO DO HORIZONTE DE CURTO PRAZO

A metodologia deste trabalho consiste em realizar previsão de carga no horizonte de curto prazo, através do desenvolvimento de um sistema inteligente, baseado nas técnicas das RNA, utilizando a arquitetura *perceptron* de múltiplas camadas com aprendizagem através do algoritmo de treinamento *Levenberg-Marquardt*.

O modelo proposto foi desenvolvido, treinado e simulado no software Matlab, utilizando dados reais de demanda média, energia e temperatura como entradas do sistema. Para a sua aplicação desenvolveu-se um script com interface visual facilitando a sua utilização.

A visão geral da solução desenvolvida para a previsão de carga no curto prazo é representada na Figura 9. Na Figura 12 é detalhado o Modelo Computacional desenvolvido para realizar a solução da previsão de carga no horizonte de curto prazo.

Figura 9 – Visão geral para previsão de carga



Fonte: Próprio autor

De acordo com o diagrama apresentado na Figura 9, inicialmente analisaram-se os fatores influentes no comportamento da carga. Com a obtenção dos dados disponíveis mais influentes no comportamento da curva de carga: demanda, energia e temperatura, utilizou-se como entrada para o sistema desenvolvido.

Posteriormente, com os dados tratados e disponibilizados nas entradas do modelo computacional, objetivou-se na aprendizagem da rede através do uso de um algoritmo de treinamento, permitindo a RNA aprender através dos dados históricos inseridos como entradas.

Após a etapa de aprendizagem, a rede tem a capacidade de generalizar as saídas, simulando a projeção da curva de carga para o próximo dia, sendo possível então comparar os dados projetados com os dados reais e por fim validar através do cálculo de erro médio, medindo a eficiência do sistema desenvolvido.

4.1 FATORES INFLUENTES NA DEMANDA

Há diversos fatores que afetam direta e indiretamente o processo de previsão da carga, para cada horizonte a ser previsto possui variáveis influentes específicas, e nem sempre os históricos dos dados necessários estão disponíveis, o que pode trazer dificuldades ao processo (MILKE et al., 2017).

De forma geral, considerando todos horizontes de previsão, vários fatores podem influenciar no comportamento da carga, conforme Antunes (2013), de forma resumida podem ser divididos em quatro categorias:

- a) fatores econômicos: tarifa de energia elétrica, tendências econômicas, área demográfica, entre outros;
- b) fatores de tempo: comportamentos cíclicos e efeitos sazonais;
- c) fatores aleatórios: eventos que causam variações no comportamento da carga e não podem ser explicados;
- d) fatores climáticos: temperatura, velocidade do vento, umidade relativa do ar, temporal, chuva, neve, entre outros.

Porém, o conhecimento das variáveis que mais influenciam no horizonte de previsão da carga permite representar o seu comportamento, servindo seu próprio histórico de dados como uma entrada para o modelo adotado (NIGITZ; GÖLLES, 2019).

Muitas limitações e dificuldades podem ser encontradas para previsão à curto prazo, devido à forte ligação do comportamento da curva de carga em função da temperatura, umidade,

sensação térmica e o comportamento de uso do consumidor (CARCEDO; GARCÍA, 2019; COSTA, 2017; DE ANDRADE; DA SILVA, 2016; ELJAZZAR; HEMAYED, 2016; LIANG; NIU; KONG, 2019; NIGITZ; GÖLLES, 2019).

A qualidade da previsão de carga com técnicas de inteligência artificial está diretamente relacionada com a escolha de variáveis mais impactantes no comportamento da carga, bem como a disponibilidade dos dados históricos para analisar o comportamento deste sistema, para então criar a etapa de aprendizado (ALTRAN, 2010; BARRETO, 2017; GUIRELLI, 2006).

4.1.1 Dados de entrada do sistema

Efetuuou-se uma avaliação dos principais fatores que influenciam na demanda diária, além da carga do sistema, com uma quantidade de histórico de dados suficientes para o treinamento e validação da rede.

As séries históricas adotadas foram àquelas variáveis consideradas influentes no comportamento da curva de carga diária. Foram utilizadas as seguintes variáveis:

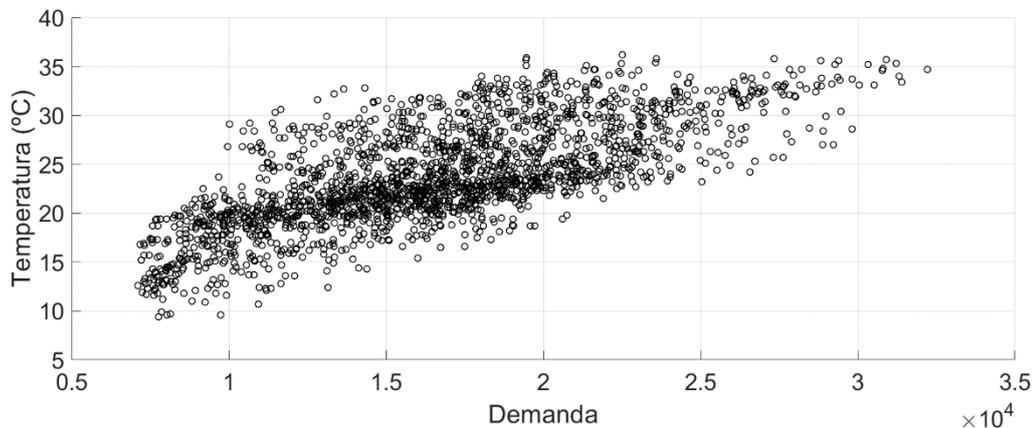
- a) demanda média em intervalos de 15 e 60 minutos (MW);
- b) temperatura máxima (C°) em intervalos de 15 e 60 minutos;
- c) temperatura mínima (C°) em intervalos de 15 e 60 minutos;
- d) consumo de energia elétrica (kWh) acumulado a cada 15 minutos.

As variáveis obtidas são utilizadas como dados de entrada, sendo aplicados no método computacional para que sirvam de treinamento da rede, possibilitando que esta rede generalize as séries históricas, produzindo um resultado de saída. As variáveis de temperatura foram disponibilizadas em períodos de hora, portanto, foi necessário repetir o mesmo valor para os demais 3 períodos de 15 minutos da hora nas simulações com os dados integralizados em períodos de 15 minutos.

O comportamento do consumo de carga diário, frequentemente, possui forte correlação com os fatores climáticos (CHEMETOVA, 2018). Esse comportamento do uso sistema elétrico pelo consumidor tem grande influência nos resultados (KUO, et al., 2017).

As correlações entre demanda e temperatura podem ser analisadas na Figura 10. A correlação indica a força e a direção do relacionamento linear entre essas variáveis, desta maneira podemos dizer que há uma correlação positiva e comprovar a relação de causa e efeito.

Figura 10 – Correlação temperatura x demanda



Fonte: Próprio autor

Na região em análise, foi constatado que a temperatura tem forte influência na variação da curva de carga da demanda diária (MILKE et al., 2017). A Figura 10 demonstra a sensibilidade que existe entre a temperatura e a demanda no sistema em estudo, observa-se ainda que o aumento da temperatura tem um relacionamento linear no aumento na carga diária.

Os estudos comprovam que no curto prazo a demanda varia de acordo com a temperatura do ar, sensação térmica, velocidade do vento e a umidade. Mas, a temperatura é a variável climática que tem mais impacto no comportamento da demanda no curto prazo, podendo então ser a melhor representação da relação entre elas (DE ANDRADE; DA SILVA, 2016; LIANG; NIU; HONG, 2019; SILVA et al., 2017b).

4.1.2 Normalização dos dados

Como as séries de dados utilizadas tem um comportamento crescente, é necessário realizar a normalização dos dados, para que estes fiquem dentro de um intervalo de valores adequados para o processamento pela rede neural (ROMERA; MORÁN; FERNÁNDEZ, 2006).

Para o bom funcionamento do sistema na estrutura das RNA's é necessário normalizar os dados a serem aplicados na entrada do sistema para impedir que uma dimensão se sobreponha em relação às outras e evitar que o aprendizado seja estagnado, implicando ainda numa melhor precisão numérica à frente às operações matemáticas a ser realizadas pela rede (CARMONA et al., 2002).

A normalização dos dados foi realizada na camada escondida, utilizando a função de ativação tangente hiperbólica, o qual possui uma faixa de [-1 1]. O método de normalização apresentado na equação (11), resulta na transformação dos dados para uma mesma faixa de valores.

$$x = \left[\left(\frac{D_{original} - D_{mínima}}{D_{máxima} - D_{mínima}} \right) * 2 \right] - 1 \quad (10)$$

A normalização dos dados não resulta em perda na representatividade das informações, uma vez que pode ser recuperado o seu valor original.

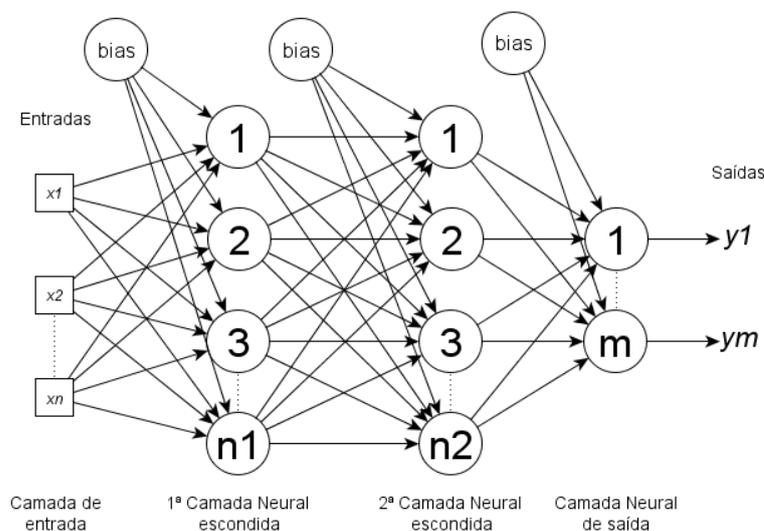
4.2 MODELO COMPUTACIONAL DESENVOLVIDO BASEADO EM RNA

No capítulo 3 de Redes Neurais foram apresentadas as principais características dos sistemas baseados em RNA, abordando as principais arquiteturas e algoritmos de treinamentos utilizados.

A arquitetura do sistema proposto foi do tipo MLP (*Multilayer Perceptron* ou *Perceptron* de múltiplas camadas) conforme apresentado na Figura 11 abaixo.

O modelo utilizado é amplamente aplicado em predição de séries não lineares, o qual possui a capacidade para identificar a evolução temporal (ROMERA; MORÁN; FERNÁNDEZ, 2006).

Figura 11 – Rede RNA - *Multilayer Perceptron*

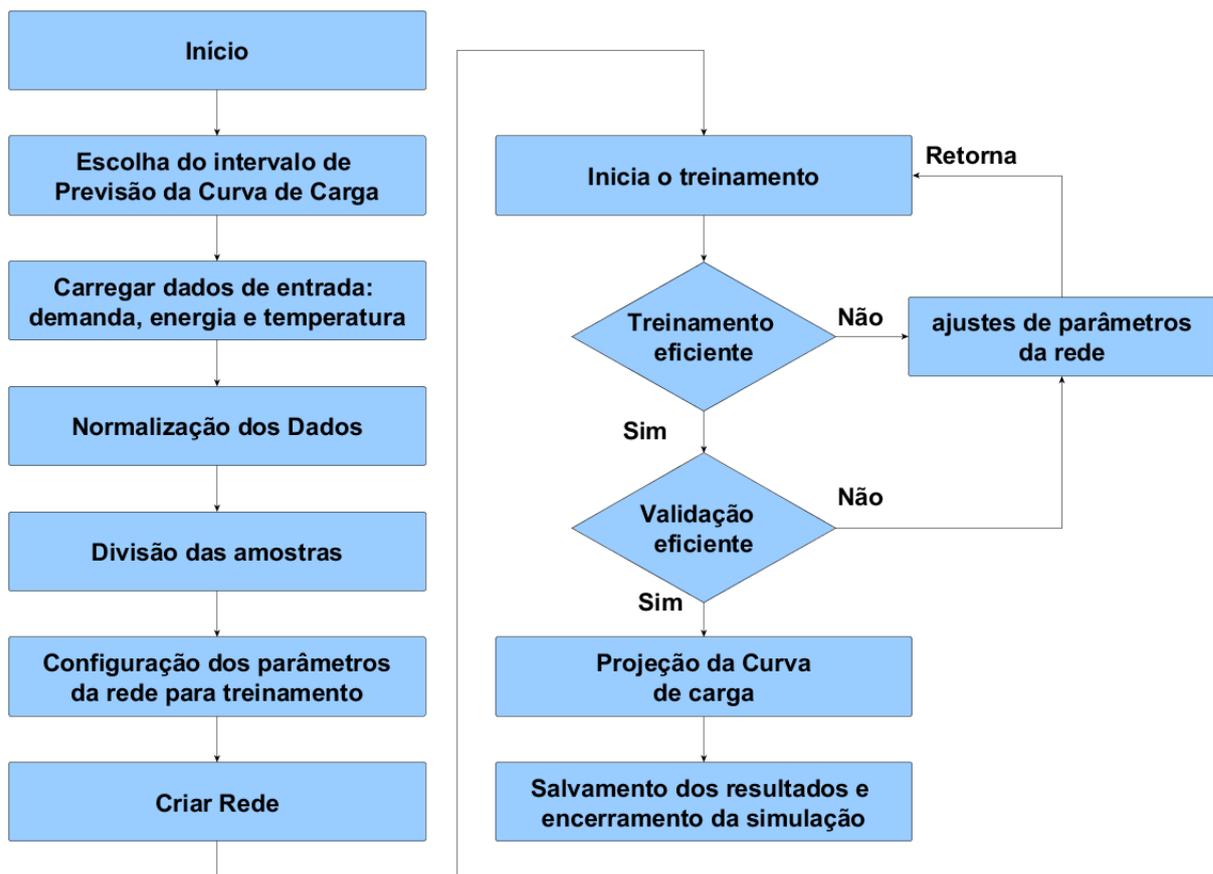


Basicamente, conforme pode ser visualizado na Figura 11 acima, a estrutura é composta por um conjunto de camada de entrada, uma ou mais camadas intermediárias (ocultas) e uma camada de saída. Os sinais de entrada são propagados da entrada seguindo de camada a camada pela rede, o conhecimento é adquirido por um algoritmo de aprendizado supervisionado (MOREIRA, 2015).

A conexão entre os neurônios deste modelo acontece por meio de um ajuste de pesos, cujos valores representam o conhecimento adquirido pela rede. Outra componente que merece destaque neste modelo é o peso bias, responsável por controlar a entrada dos valores na função de ativação do neurônio artificial.

O sistema desenvolvido baseado nos modelos matemáticos de RNA foi implementado no software Matlab, no fluxograma da Figura 12 é detalhado o modelo computacional desenvolvido.

Figura 12 – Fluxograma do modelo computacional desenvolvido



Conforme o fluxograma da Figura 12, ao iniciar o sistema, primeiramente escolhe-se o intervalo de integralização da curva de carga a ser projetada (15 ou 60 minutos), logo em seguida os dados de entrada são carregados no programa, todas as amostras são normalizadas na faixa de $[-1 \ 1]$. Os dados automaticamente são separados em treinamento, validação e teste.

A partir da divisão, cria-se o banco de dados da rede neural com os respectivos dados de treinamento normalizados e as saídas desejadas. Depois, é realizada a configuração dos principais parâmetros para o aprendizado do sistema e a criação da RNA.

Caso o treinamento apresente bom desempenho com erros aceitáveis e respostas adequadas, pode ser iniciada a validação, caso contrário, deve-se iniciar novamente o treinamento da rede. Por fim, após a validação a rede apresenta os resultados do treinamento e é possível realizar a projeção da curva de carga.

4.3 TREINAMENTO DA REDE

Para realizar o treinamento da rede neural desenvolvida implementou-se o algoritmo *Levenberg-Marquardt*.

Adotou-se aprendizagem supervisionada para a realização do treinamento, ou seja, a rede aprende na medida em que o especialista verifica se os dados fornecidos estão gerando aprendizagem para a rede, tomando o cuidado para que o aprendizado não seja estagnado ou viciado. (DA SILVA; SPATTI; FLAUZINO, 2016; DE MACEDO, 2014; YAHYA, HADI, PUTRANTO, 2018).

É possível afirmar que o treinamento da rede neural é o ponto onde se obtém o sucesso ou o fracasso da rede, neste processo o modelo é submetido ao aprendizado, através de uma série de dados de entrada. A técnica para obter um eficiente treinamento implica na atenção ao configurar certos parâmetros, tais como: taxa de aprendizagem, número de camadas, número de épocas, ajustes dos pesos (realizado automaticamente pelo algoritmo) e máxima validação de falhas.

O treinamento ou o aprendizado da rede ocorre em ciclos (épocas), que correspondem ao número de iterações do processo em que são aplicados todos os dados de entrada do treinamento, visando ajustar e diminuir o erro da camada de saída da rede (MILKE et al., 2017).

O número de iterações depende, aproximadamente, da quantidade de dados. A validação de falhas representa um teste de previsão antes da finalização da etapa de treinamento da rede (DE MACEDO, 2014).

O ajuste dos pesos possuiu grande influência na velocidade do aprendizado e na qualidade da solução obtida após a convergência. Uma boa escolha para os valores iniciais dos pesos sinápticos e limiares da rede pode ser de grande ajuda para um projeto de rede ser bem-sucedido. Diversas estratégias de inicialização dos pesos são sugeridas na literatura. Os métodos mais simples para inicialização de pesos baseiam-se em uma distribuição uniforme aleatória.

Geralmente as RNA são treinadas de maneira que as entradas projetem uma saída específica, a rede é ajustada em função do comparativo da entrada com os resultados (PANDEY et al., 2014).

Neste trabalho, os pesos são distribuídos uniformemente em intervalo aleatórios, gerados automaticamente pelo algoritmo. Para a determinação do número de camadas escondidas e número de neurônios, pesquisou-se na literatura especializada as configurações e parametrizações utilizadas por diversos autores (BENTO et al., 2019).

Adotou-se um esquema de tentativa e erro, através do aumento do número de camadas e neurônios, gradualmente, calculando seu respectivo erro. Salienta-se que acima de duas camadas escondidas a rede não consegue adquirir boa convergência (ROMERA; MORÁN; FERNÁNDEZ, 2006).

4.3.1 Algoritmo para Treinamento dos Dados de Entrada

O algoritmo utilizado para realizar o treinamento da rede foi o *Levenberg-Marquardt*, o qual foi implementado dentro do script desenvolvido por possuir um bom desempenho do processamento do treinamento.

O algoritmo de aprendizado é um conjunto de regras bem definidas visando a solução do problema. Foi adotado aprendizado supervisionado, ou seja, a rede aprende com um conjunto de saídas desejadas.

4.3.2 Indicador de erro de previsão

Para gerenciar o processo de previsão é necessário reduzir os desvios dos erros, promovendo confiabilidade ao método de previsão do sistema. Os indicadores de previsão permitem analisar o quão perto a previsão realizada aproximou-se dos dados reais, quanto menor os erros percentuais de previsão melhor a eficiência do sistema.

Neste processo, para verificar o desempenho da rede e medir sua precisão foi utilizado para o treinamento da rede o erro MÍNIMO quadrático (MSE), o erro percentual absoluto médio

(MAPE) e o erro percentual absoluto (APE), comparando os valores estimados com os valores reais da carga, obtidos através das equações (11), (12) e (13), respectivamente.

$$MSE = \frac{1}{N} \sum_{j=1}^N (a_j - y_j)^2 \quad (11)$$

$$APE(\%) = \frac{(D_o - D_r)}{D_o} * 100 \quad (12)$$

$$MAPE = \frac{1}{N} \sum_N APE \quad (13)$$

Na equação (11) o a_j significa o valor real, y_j o valor resultante, N é o número de período (amostras) das previsões. Na equação (12) e (13) D_o significa o valor da demanda original, D_r o valor da demanda real e N o período analisado.

Para uma rede neural, o desempenho do treinamento é expresso em função da soma dos erros quadráticos em cada amostra. A maioria dos trabalhos utiliza o indicador MAPE como fator de avaliação do erro (PANDEY et al., 2014).

4.4 SIMULAÇÃO DA REDE

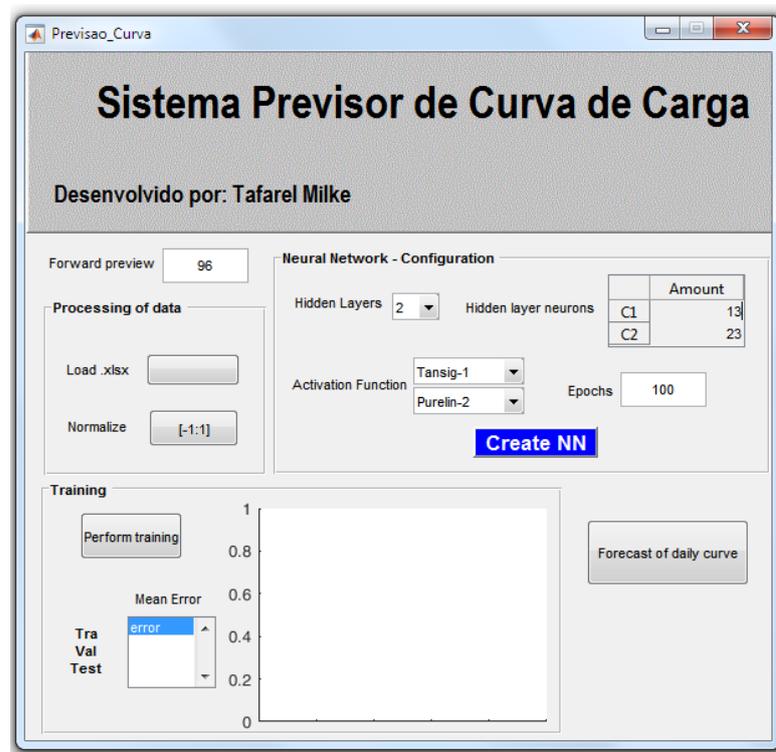
Na previsão de carga utilizando redes neurais, pode-se simplificar o modelo de sistema em três partes: entrada do sistema, treinamento e previsão. O modelo proposto foi desenvolvido e simulado no software Matlab e segue as seguintes etapas descritas no item 4.4.1 para realizar a configuração da rede, treinamento, simulação e previsão da curva de carga.

As próximas subseções evidenciam exemplo de projeção da curva de carga, com um passo a passo da configuração necessária para o modelo de previsor, particularmente, expondo as etapas de treinamento e de previsão da curva de carga do dia seguinte.

4.4.1 Configuração e parametrização da rede

Para realizar o treinamento e as simulações utilizando o sistema desenvolvido, deverá ser seguida a sequência de configurações previstas no fluxograma da Figura 12 e na interface do sistema desenvolvido exposto na Figura 13.

Figura 13 – Interface do sistema desenvolvido



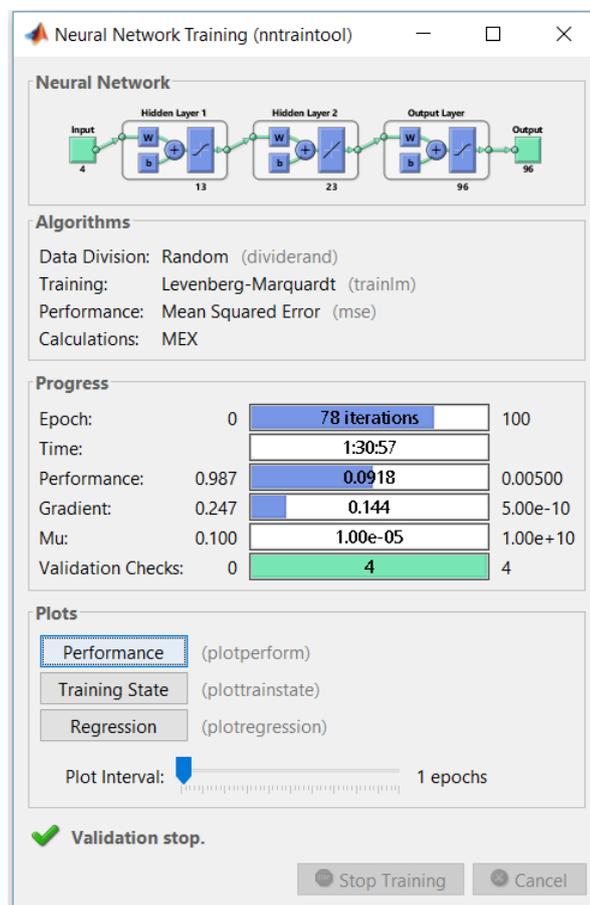
Fonte: Próprio autor

- a) *forward preview*: digitar o valor de 24 para curva de carga em intervalos de 60 em 60 minutos ou 96 para curva de carga em intervalos de 15 e 15 minutos;
- b) *load*: seleção dos dados de entrada, escolher o arquivo de dados, que será importado em formato “xlsx”. Ressalta-se que o usuário tem a possibilidade de manipular a quantidade de dados e de fatores a ser utilizados;
- c) *normalize*: clicar no botão para realizar a normalização dos dados dentro da faixa especificada;
- d) *hidden layers*: selecionar o número de camadas ocultas desejadas;
- e) *hidden layers neurons*: selecionar a quantidade de neurônios por cada camada oculta;
- f) *activation function*: selecionar o tipo de função para cada camada oculta;
- g) *epochs*: digitar o número de épocas ou iterações;
- h) *create NN*: clicar para a criação da rede neural;
- i) *perform training*: clicar para iniciar a etapa de treinamento da rede.

Iniciado o treinamento da rede, os dados automaticamente são separados em treinamento, validação e teste. Os pesos sinápticos são distribuídos uniformemente em intervalo aleatórios, gerados automaticamente pelo algoritmo.

Na Figura 14 é apresentada a janela de treinamento da rede com esta etapa já finalizada, apresentando o desempenho, andamento da etapa de treinamento, quantidade de iterações calculadas e o tempo de processamento.

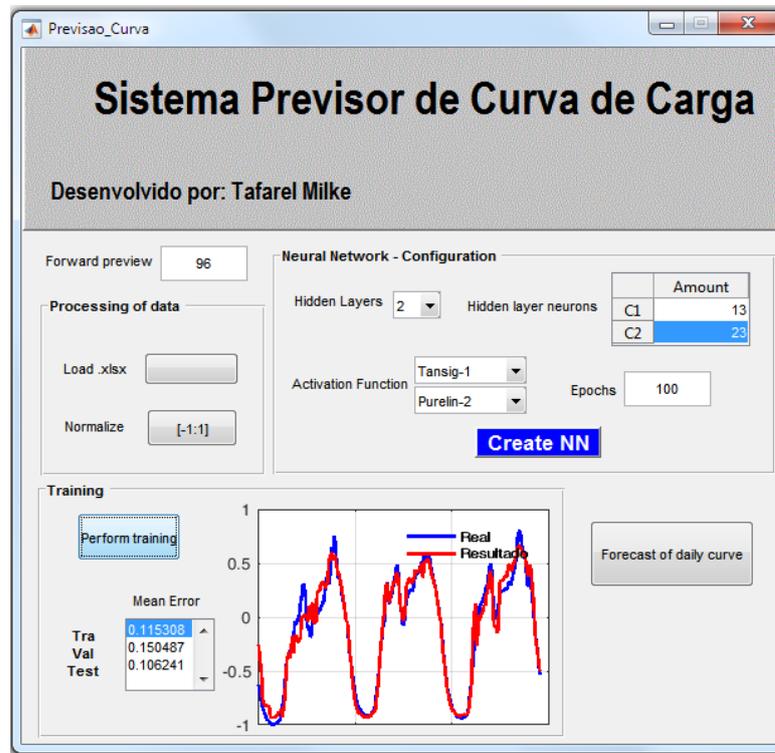
Figura 14 – Exemplo de treinamento da RNA



Fonte: Próprio autor

Ao concluir a etapa de treinamento, é necessário avaliar o desempenho realizado pela rede, o resultado dos erros de treinamento “*mean error*” é apresentado no item “*training*” conforme demonstra a Figura 15.

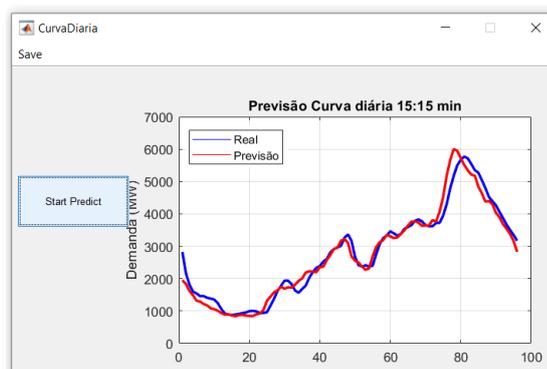
Figura 15 – Exemplo de resultado do treinamento da RNA



Fonte: Próprio autor

Finalizado o treinamento, e caso este apresente bom desempenho com erros aceitáveis, pode ser iniciada a projeção da curva de carga do próximo dia clicando em “Forecast of daily curve” e logo após em “Start Predict” permitindo a visualização gráfica desta, conforme exemplo da Figura 16.

Figura 16 – Exemplo de resultado da projeção de curva de carga



Fonte: Próprio autor

Concluída a simulação da projeção da curva de carga, pode ser visualizado o comportamento do desempenho da simulação, através da comparação dos valores projetados pelo sistema com os valores reais da curva de carga, como demonstrado na Figura 16.

Caso os resultados estejam dentro dos limites aceitáveis e atendam o objetivo está concluída a simulação. Os resultados da curva de carga projetada podem ser salvos em um arquivo do Excel no formato “xlsx”, através do comando “Save”.

Caso contrário, deverá retornar a etapa de treinamento da rede, onde o especialista deverá alterar os parâmetros da rede e realizar um novo treinamento, com o intuito de melhorar o desempenho e diminuir os erros.

A escolha dos parâmetros da RNA foi definida através de diversas simulações realizadas, com base em variações destes valores dentro de um intervalo especificado na Tabela 2 e na Tabela 3.

Tabela 2 – Configurações da rede utilizadas para as simulações da SE-1

Parâmetro	Valor
Entrada	24 e 96
Número de Camadas Ocultas	2
Número de Neurônios na Camada 1	6 a 13
Número de Neurônios na Camada 2	11 a 23
Função de Ativação da Camada 1	Logística
Função de Ativação da Camada 2	Linear
Número de iterações	100

Fonte: Próprio autor

Tabela 3 – Configurações da rede utilizadas para as simulações da SE-2

Parâmetro	Valor
Entrada	24 e 96
Número de Camadas Ocultas	1
Número de Neurônios na Camada 1	10 a 25
Número de Neurônios na Camada 2	-
Função de Ativação da Camada 1	Logística
Função de Ativação da Camada 2	-
Número de iterações	100

Fonte: Próprio autor

4.4.2 Hardware utilizado

As simulações foram realizadas no software Matlab utilizando um computador DELL INSPIRION com processador Intel Core i7 7ª Geração de 2.7 GHz, memória RAM de 16 GB DDR4 e com placa de vídeo NVIDIA GeoForce GTX 940M 4GB.

4.5 INTERFACE GRÁFICA

Para possibilitar um melhor acesso do usuário à ferramenta de previsão, foi desenvolvido uma interface gráfica do sistema. A construção da interface foi consolidada através de pesquisas realizadas na área de Interface Homem Máquina.

As interfaces ou janelas gráficas, também conhecidas como Graphical User Interfaces ou GUIs, são partes do sistema computacional que determinam como os usuários operam e controlam o sistema.

No desenvolvimento do sistema foi utilizada a plataforma GUIDE (*Creating Graphical User Interfaces*) onde se realiza a programação no próprio Matlab. A interface gráfica teve seu projeto inspirado em sistemas que também adotaram redes neurais, para diferentes problemas.

O GUIDE fornece inúmeros recursos, tais como gráficos, botões, menus, caixas de texto, entre outros, que possibilitam a interação do usuário com dados e modelos. O layout principal com a inicialização e ajustes dos parâmetros é apresentado na Figura 13.

4.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo, foi apresentada a metodologia e a estruturação utilizada no sistema de previsão de carga no curto prazo. Foram detalhados os procedimentos do sistema predictor, abordando as variáveis de entrada do sistema, modelo computacional utilizado, treinamento e simulação da RNA.

Através da interface gráfica desenvolvida, foi possível demonstrar detalhadamente as configurações e parametrizações que podem ser utilizadas para processar o treinamento e a simulação da RNA.

5 ANÁLISE DOS RESULTADOS DO ESTUDO DE CASO

No modelo foram testadas, empiricamente, diferentes formas de carregar as amostras na camada de entrada da rede, configurando os parâmetros de diferentes maneiras ao longo das simulações para aperfeiçoar o treinamento da rede e conseqüentemente obter uma curva de carga mais próxima da real.

Os experimentos foram realizados com dados reais de uma distribuidora de energia elétrica do noroeste do estado do Rio Grande do Sul. Para a aplicação da metodologia de previsão de carga de curto prazo foi analisada a curva de carga de diversos dias nos dois pontos (subestações de distribuição) de conexão, para a simplificação foi adotada a seguinte denominação: SE-1 e SE-2.

Para os resultados apresentados nas simulações foram utilizadas no sistema as seguintes configurações contidas nas Tabelas 4 e 5.

Tabela 4 – Configurações da rede para simulações com dados da SE-1

Parâmetro	Valor
Amostras de saída	24 e 96
Número de Camadas Ocultas	2
Número de Neurônios na Camada 1	13
Número de Neurônios na Camada 2	23
Função de Ativação da Camada 1	Tansig (Logística)
Função de Ativação da Camada 2	Purelin (Linear)
Número de iterações	100

Fonte: Próprio autor

Tabela 5 – Configurações da rede para simulações com dados da SE-2

Parâmetro	Valor
Amostras de saída	24 e 96
Número de Camadas Ocultas	1
Número de Neurônios na Camada 1	25
Número de Neurônios na Camada 2	-
Função de Ativação da Camada 1	Tansig (Logística)
Função de Ativação da Camada 2	-
Número de iterações	100

Fonte: Próprio autor

Realizou-se o treinamento e simulação da RNA com os dados integralizados em períodos de 15 minutos e 60 minutos, utilizando uma quantidade de amostras que permitiu o bom aprendizado ao sistema, proporcionando a capacidade de projetar a curva de carga do dia seguinte com 24 ou 96 amostras para as próximas 24 horas do dia seguinte.

Nas simulações com dados integralizados em 15 minutos foram utilizados como entrada as variáveis de temperatura mínima, temperatura máxima, energia acumulada e demanda média integralizada em períodos de 15 minutos.

Para as simulações com dados integralizados em 60 minutos, neste caso, se utilizou dados de temperatura mínima, temperatura máxima e a demanda média integralizada em períodos de 60 minutos, já que o valor da energia integralizada em 60 minutos será o mesmo valor da demanda média.

Nos itens 5.1 e 5.2 são apresentados os resultados encontrados para as simulações com a aplicação do modelo computacional desenvolvido.

5.1 SIMULAÇÕES SE-1

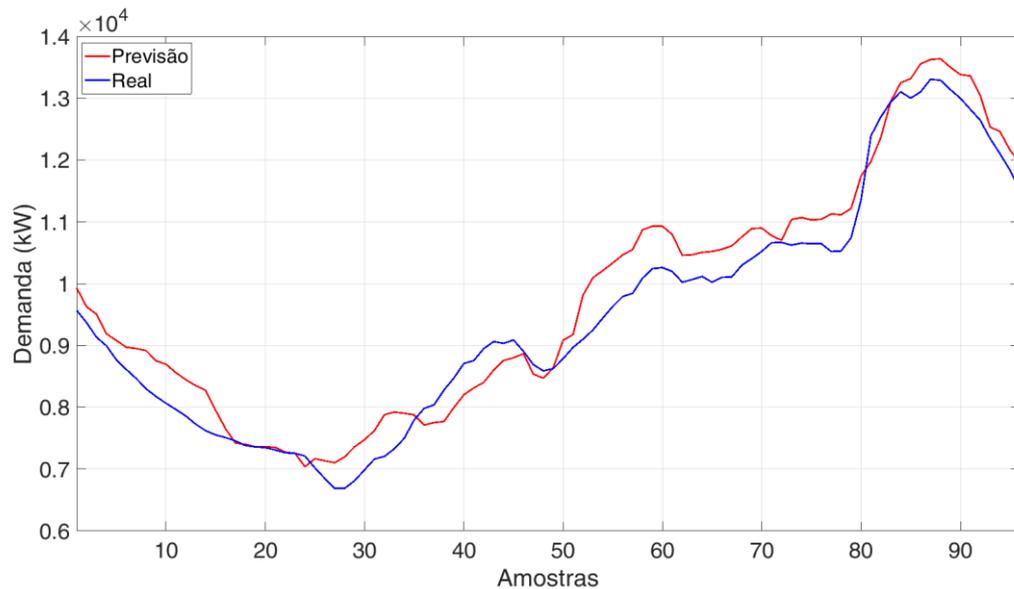
5.1.1 Simulações SE-1 – Curva de Carga do dia 29/01/2017

Para o treinamento da RNA foram utilizados os dados históricos do período entre o dia 10/01/2017 e 28/01/2017, com dados integralizados em intervalos de 15 minutos, resultando em 1.824 amostras.

Para avaliar as etapas de treinamento da rede com as séries históricas, foi utilizado o erro quadrático médio (MSE), o qual apresentou um MSE no valor de 0,47%.

Na Figura 17 é apresentado o resultado da projeção da curva de carga integralizada em 15 minutos, prevendo 96 amostras para o dia 29/01/2017.

Figura 17 – Projeção curva de carga integralizada em 15 minutos do dia 29/01/2017



Fonte: Próprio autor

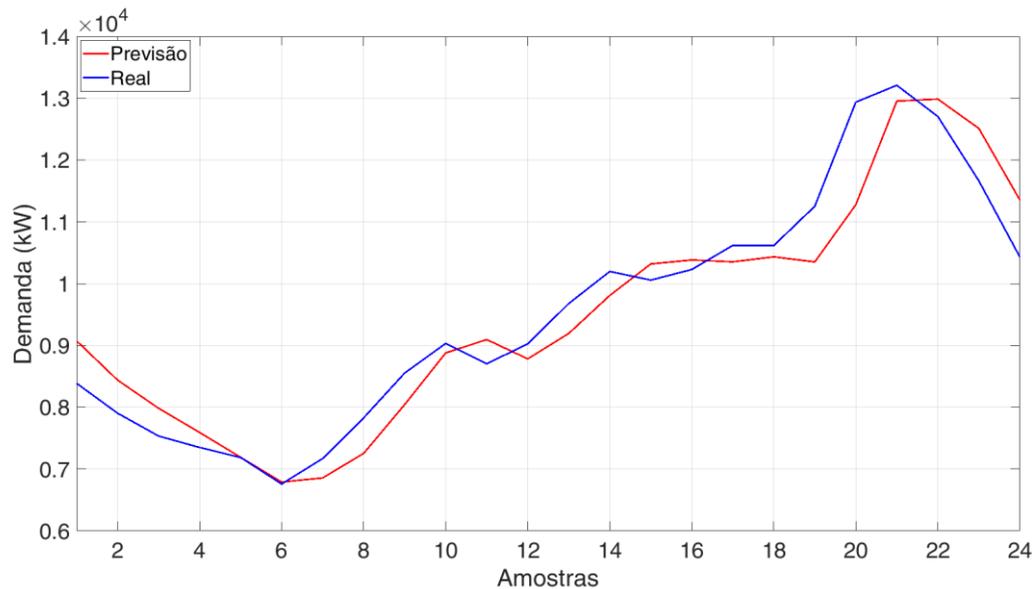
Para avaliar os resultados das simulações de projeção das curvas de carga foi utilizado o erro absoluto médio (MAPE), o qual apresentou um MAPE no valor de 2,74%.

Constatou-se que, se for utilizado uma maior quantidade de dados para o treinamento, exigirá mais tempo de esforço computacional e dependerá da análise dos dados de entrada pelo especialista para que este apresente melhor desempenho.

A solução encontrada para minimizar esta dificuldade e potencializar o treinamento foi aplicar na ferramenta com dados em intervalos de hora em hora, prevendo apenas 24 amostras à frente ao invés de 96 amostras.

Na Figura 18 é apresentada a curva de carga do dia 29/01/2019 com intervalos de integralização de 60 minutos. Para o treinamento da RNA foi considerado as variáveis de entrada no período do dia 10/01/2017 a 28/01/2017, resultando em 456 amostras, sendo o suficiente para a rede apresentar um bom aprendizado, apresentando um MSE no valor de 0,02%.

Figura 18 – Projeção curva de carga integralizada em 60 minutos do dia 29/01/2017



Fonte: Próprio autor

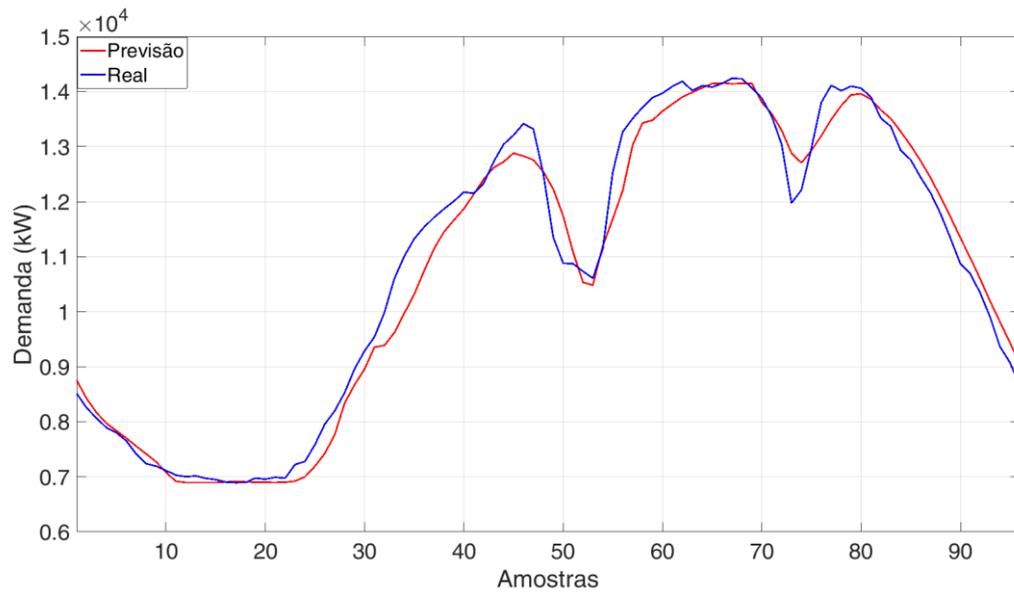
A projeção apresentada na Figura 18 apresentou um MAPE de 0,57%. Se comparada a Figura 17 visualizamos um melhor resultado médio com menor tempo de processamento da etapa de simulação.

5.1.2 Simulações SE-1 – Curva de Carga do dia 26/03/2019

Para o treinamento da RNA foi considerado as variáveis de entrada no período entre o dia 04/02/2019 a 25/03/2019. Os dados estão integralizados em intervalos de 15 minutos, resultando em 4.800 amostras.

O desempenho do treinamento apresentou um valor MSE de 0,07% e o resultado da projeção da curva de carga do dia 26/03/2019 com dados integralizados em intervalos de 15 minutos é apresentada na Figura 19.

Figura 19 – Projeção curva de carga integralizada em 15 minutos do dia 26/03/2019

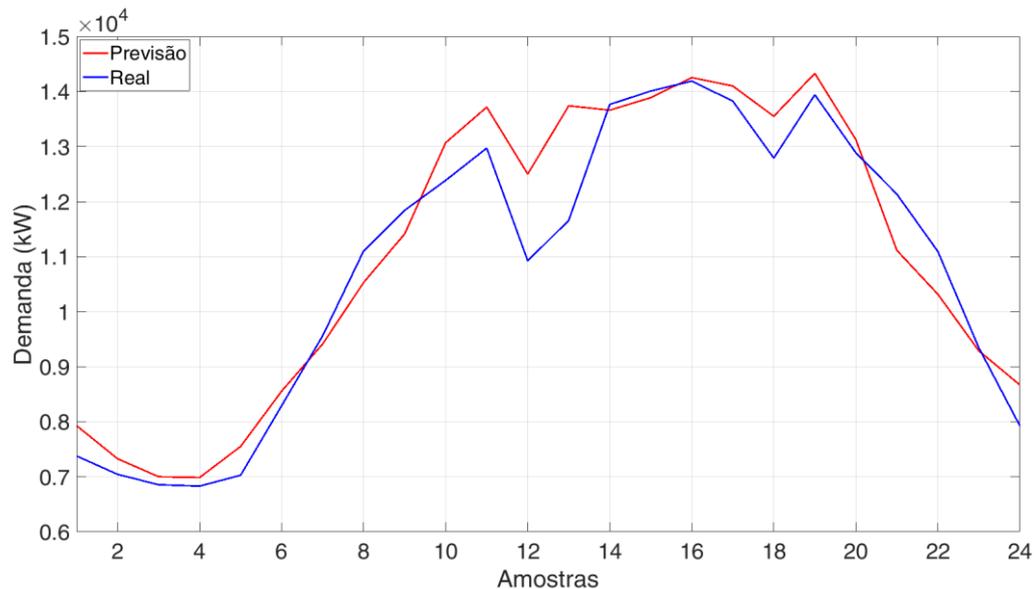


Fonte: Próprio autor

O desempenho da projeção da curva de carga da Figura 19 apresentou um MAPE no valor de 0,89%.

Na Figura 20, é apresentado a previsão da curva de carga do dia 26/03/2019, porém com os dados integralizados em intervalos de 60 minutos. Para o treinamento da RNA foi considerado as variáveis de entrada entre o dia 04/02/2019 e 25/02/2019, resultando 1.200 amostras. O desempenho do treinamento da rede apresentou um MSE de 0,12%.

Figura 20 – Projeção curva de carga integralizada em 60 minutos do dia 26/03/2019



Fonte: Próprio autor

O resultado do desempenho da projeção da curva de carga na Figura 20 apresentou um MAPE de 2,29%.

5.2 SIMULAÇÕES SE-2

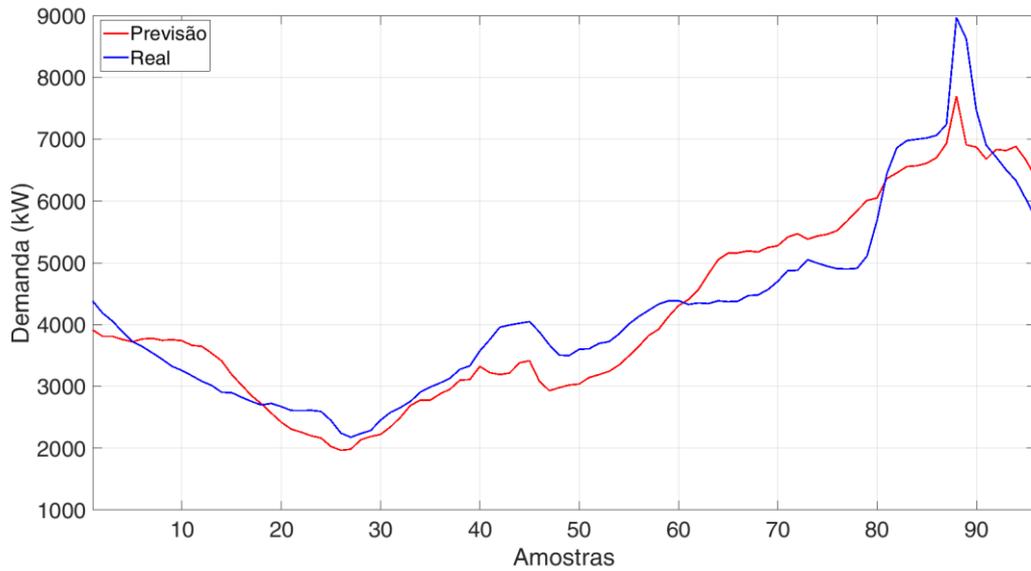
5.2.1 Simulações SE-2 – Curva de Carga do dia 29/01/2017

Para o treinamento da RNA foram consideradas as variáveis de entrada entre o dia 10/01/2017 e 28/01/2017. Os dados estão integralizados em intervalos de 15 minutos, resultando em 1.824 amostras.

Na etapa de treinamento obteve-se um MSE de 0,08%. Com os dados da SE-2 foi mais simples para obter resultados melhores na etapa de treinamento porque o comportamento dos dados era semelhante diariamente.

A Figura 21 apresenta a projeção de 96 amostras para a curva da carga do dia 29/01/2017.

Figura 21 – Projeção curva de carga integralizada em 15 minutos do dia 29/01/2017

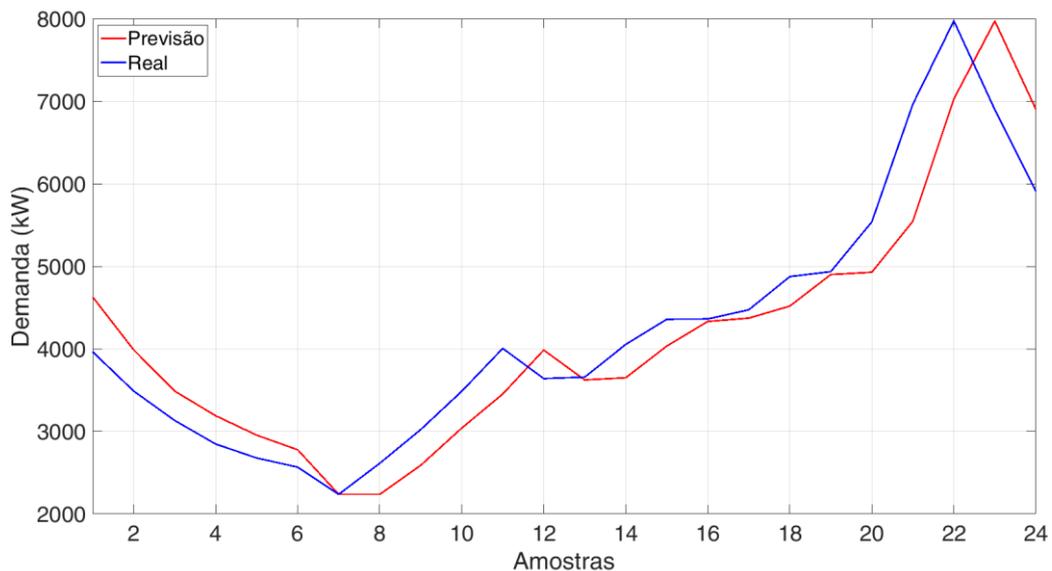


Fonte: Próprio autor

O desempenho da projeção da curva de carga da Figura 21 apresentou um MAPE no valor de 2,96%.

Na Figura 22 é apresentada a projeção da curva de carga integralizada em intervalos de 60 minutos. Para o treinamento da RNA foi considerado as variáveis históricas no período entre o dia 10/01/2017 a 28/01/2017, resultando em 456 amostras, onde o treinamento apresentou um MSE de 0,04%.

Figura 22 – Projeção curva de carga integralizada em 60 minutos do dia 29/01/2017



Fonte: Próprio autor

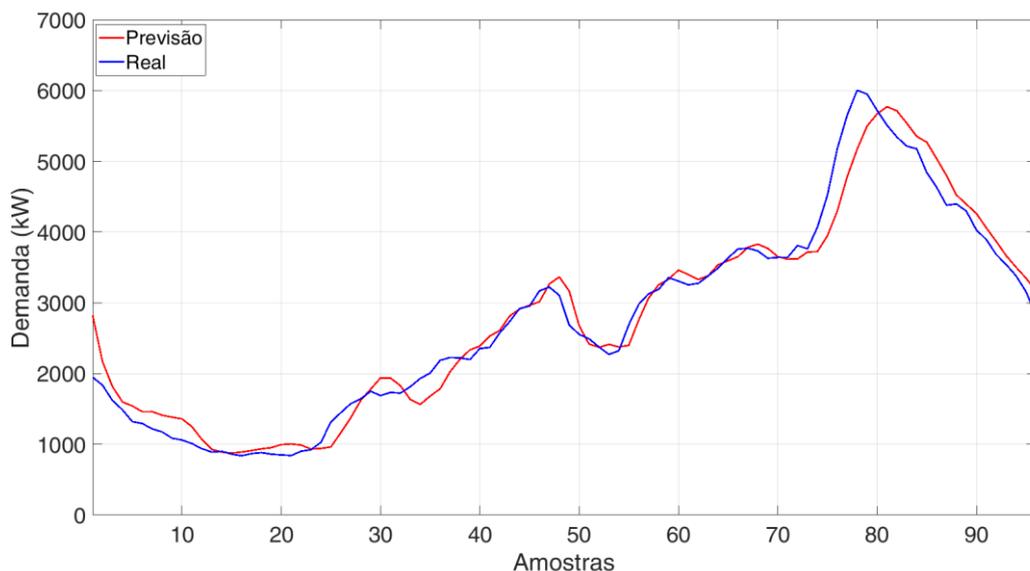
O desempenho da projeção da curva de carga do dia 29/01/2017 da Figura 22 apresentou um MAPE no valor de 1,92%.

5.2.2 Simulações SE-2 – Curva de Carga do dia 28/03/2019

Para o treinamento da RNA foi considerado o comportamento das variáveis do dia 04/02/2017 a 27/03/2019. Os dados estão integralizados em intervalos de 15 minutos, resultando em 4.992 amostras.

Na etapa de treinamento obteve-se um desempenho de MSE de 0,07%, e o resultado da projeção com 96 amostras para a curva da carga prevista para o dia 28/03/2019 é exposto na Figura 23.

Figura 23 – Projeção curva de carga integralizada em 15 minutos do dia 28/03/2019

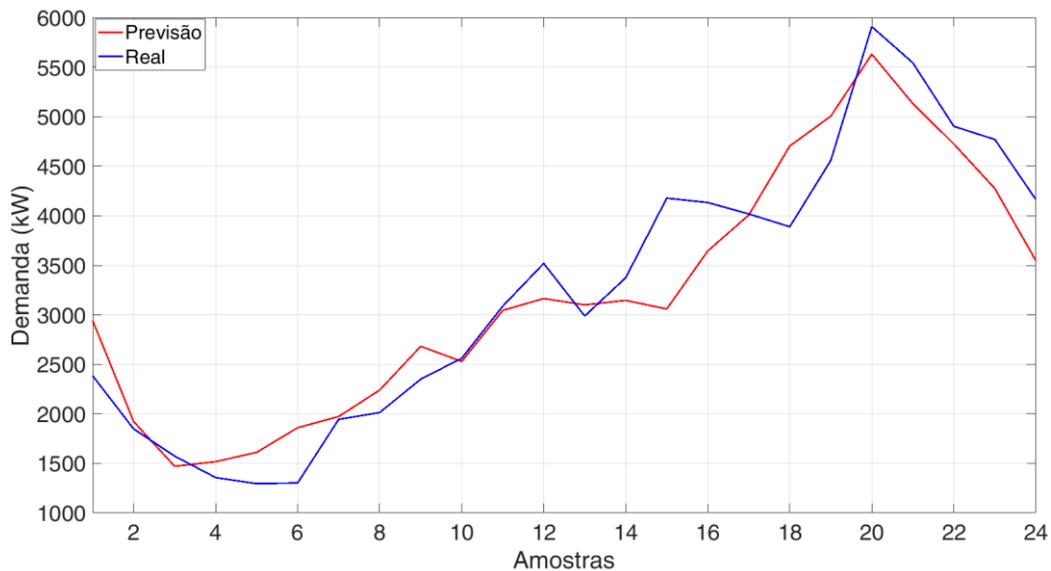


Fonte: Próprio autor

A projeção da curva de carga integralizada em 15 minutos do dia 28/03/2019 apresentada na Figura 23 apresentou um MAPE de 1,66%.

A Figura 24 demonstra a previsão da curva de carga do dia 28/03/2019 com dados integralizados em intervalos de 60 minutos. Para o treinamento da RNA foi considerado as variáveis históricas no período do dia 04/02/2019 a 27/03/2019, resultando em 1.248 amostras, o desempenho do treinamento da rede apresentou um MSE de 0,12%.

Figura 24 – Projeção curva de carga integralizada em 60 minutos do dia 28/03/2019



Fonte: Próprio autor

O resultado do desempenho da projeção da curva de carga do dia 28/03/2019 é exposta na Figura 24 e apresentou um MAPE de 0,53%.

5.3 ANÁLISE COMPARATIVA DAS SIMULAÇÕES

Ao realizar uma análise comparativa entre as simulações, pode-se afirmar que ambas as maneiras de manipular os dados atendem os requisitos para treinamento da rede, resultando em um bom aprendizado da rede através da utilização das variáveis disponíveis que são influentes no comportamento da carga.

Durante os processos de treinamento, o tempo de esforço computacional requerido por treinamento oscilou em torno de 120 minutos para cada treinamento com dados integralizados em períodos de 15 minutos e aproximadamente 20 minutos considerando os dados integralizados em períodos de 60 minutos.

O comparativo do MSE durante as etapas de treinamento variou na faixa de 0,02% a 0,47%, com isso constatou-se que os treinamentos com melhores desempenhos resultaram em uma curva de carga mais próxima a desejada com um menor valor de MAPE.

Tabela 6 – Análise comparativa do MAPE nas projeções realizadas

Curva Projetada e Período de Integralização	MAPE Ano 2017	MAPE Ano 2019
SE 1 - 15 min	2,74%	0,89%
SE 1 - 60 min	0,57%	2,29%
SE 2 - 15 min	2,96%	1,66%
SE 2 - 60 min	1,92%	0,53%

Fonte: Próprio autor

Na Tabela 6 consta de forma resumida os resultados encontrados nas projeções das curvas de carga com o sistema RNA desenvolvido. Observou-se que os melhores resultados dependem do comportamento histórico da curva de carga e de um treinamento eficiente. Portanto, sistemas que possuem uma curva de carga diária semelhante, sem muitas variações, apresentam uma melhor eficiência durante o treinamento, conseqüentemente melhores resultados nas projeções.

Através do comparativo, constatou-se que os procedimentos adotados resultaram em saídas eficientes, sendo possível visualizar o comportamento da carga do dia seguinte dentro de valores considerados como boa precisão, conforme descrito nas publicações mais recentes na literatura especializada (REJC; PANTOS, 2011; SINGH; SINGH, K.; PALIWAL, 2016; CHEMETOVA, 2018).

5.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foram apresentados os resultados da previsão de carga no curto prazo, utilizando os dados históricos reais de energia, demanda e temperatura, realizados no mercado de suprimento de uma distribuidora de energia elétrica localizada na região noroeste do estado do Rio Grande do Sul.

Com o sistema previsor desenvolvido foi possível comprovar que as variáveis de energia, demanda e temperatura utilizadas nas simulações têm forte impacto no comportamento da carga.

Através dos testes realizados, percebeu-se que os valores dos parâmetros usados para treinamento, relativo aos melhores resultados, para os dois intervalos utilizados, permanecem praticamente no mesmo patamar.

Foi possível, também, demonstrar que os métodos que utilizam inteligência artificial fornecem resultados mais precisos, se comparado com os métodos estatísticos encontradas na literatura, apresentando o valor de erro menor ou no mínimo semelhante.

Conclui-se então, que ao utilizar os dados de entrada em intervalos de 60 minutos para o treinamento da rede, a ferramenta apresentou melhor performance e o processamento requereu menor tempo de esforço computacional, resultando no melhor desempenho da etapa de treinamento. Desta forma é possível antecipar a visualização da curva de carga do dia seguinte, tendo maior tempo para planejar e implantar a tomada de decisões caso seja necessária alguma interação com a rede elétrica.

As redes neurais artificiais são técnicas computacionais que têm se mostrado extremamente eficientes na solução de problemas de previsão de carga, auxiliando na antecipação da tomada de medidas necessárias para a operação e o planejamento de sistemas elétricos (ALTRAN, 2010).

6 CONSIDERAÇÕES FINAIS

6.1 CONCLUSÕES

Este trabalho apresentou uma metodologia para realizar a previsão de carga de curto prazo, considerando um horizonte de projeção de 24 horas, através do desenvolvimento de uma ferramenta computacional usando o software Matlab, baseado em técnicas de redes neurais artificiais aplicadas a um estudo de caso.

Através da revisão bibliográfica, apresentam-se os principais métodos e ferramentas utilizadas para previsão de demanda no curto prazo nos últimos anos, em que se destaca a grande utilização das redes neurais no horizonte de curto prazo.

O modelo adotado para realizar a previsão foi escolhido por ser consolidado na literatura especializada, com boa eficiência e facilidade em trabalhar com os dados, permitindo que o especialista ajuste os parâmetros e escolha das variáveis que deseja utilizar como entradas no modelo.

O principal objetivo em realizar previsão de carga com modelo computacional está na possibilidade de evidenciar o desempenho dos sistemas inteligentes que trabalham com variáveis que não possuem linearidade, os quais se adaptam por experiência, com a capacidade de aprendizado com os dados utilizados e produzem resultados em sua saída devido a sua habilidade de generalização.

As séries históricas utilizadas de entrada no modelo computacional foram dados reais históricos de demanda, energia e temperatura. Os dados de energia e demanda média foram obtidos de uma distribuidora de energia elétrica do noroeste do estado do RS. Os dados de temperatura são provenientes de uma estação meteorológica também localizada na cidade de Ijuí.

As entradas do sistema foram empregadas para o treinamento da rede através de um algoritmo de treinamento com aprendizado supervisionado, chamado *Levenberg-Marquardt*. Parte dos dados da série foram utilizados para afirmar os resultados, através do comparativo da curva de carga projetada com a curva de carga real do sistema.

Cabe comentar que, não existe um modelo apropriado e caracterizado para atender todos os casos de previsão de demanda, o treinamento da rede definirá a obtenção de bons resultados na sua saída.

As simulações da projeção da curva de carga, utilizando intervalos de 15 minutos, requereu um maior esforço computacional, pois foi necessário projetar uma curva com 96

amostras à frente. Os melhores valores obtidos para o MAPE foram de 0,89% com os dados da SE-1 e de 1,66% com os dados da SE-2.

As simulações da projeção da curva de carga utilizando intervalos de 60 minutos requereu um menor esforço computacional uma vez que foi necessário projetar uma curva de carga com apenas 24 amostras à frente. Os melhores valores obtidos para o MAPE foram de 0,57% com os dados da SE-1 e de 0,53% com os dados da SE-2.

Através dos resultados foi possível comprovar que a temperatura tem forte correção com o comportamento da demanda deste sistema, devido a este fato o treinamento da rede demonstrou um bom desempenho, conseqüentemente os resultados de saída do modelo foram satisfatórios e atenderam ao propósito da metodologia.

Como a RNA é um instrumento matemático, ou seja, possui a capacidade de interpretar os dados e os parâmetros da rede, a qualidade dos resultados dependerá do comportamento dos dados de entrada e da capacidade do especialista em fazer os melhores ajustes para o sistema em estudo.

Observa-se que a modelagem abordando redes neurais apresenta resultados muito próximos da demanda real. Na literatura especializada é possível encontrar, sobre o assunto, modelos que apresentaram resultados bem satisfatórios, principalmente quando comparados às outras técnicas.

Os resultados do estudo de caso comprovaram a eficiência do sistema, possibilitando sua adoção em processos preditivos com dados de outras distribuidoras, evidenciando a área de planejamento no âmbito estratégico, tático e operacional da distribuidora.

6.2 OPORTUNIDADES PARA TRABALHOS FUTUROS

Entre os trabalhos que podem ser desenvolvidos visando dar continuidade ao estudo, sugere-se a combinação do método utilizado com outras técnicas, para tornar a projeção mais aperfeiçoada e precisa. Destaca-se que também podem ser implementadas novas variáveis influentes no comportamento da carga com a finalidade de melhorar os resultados de saída. Também é possível utilizar os dados de energia e demanda integralizados em um período menor, como por exemplo, de 5 em 5 minutos, visando apresentar uma curva de carga mais detalhada para aplicação em horizonte de curtíssimo prazo.

Apesar dos resultados serem satisfatórios para a proposta, sugere-se combinação do método utilizando outras técnicas com o intuito de criar uma nova aplicação, como por exemplo, considerar como entrada do sistema o impacto das gerações distribuídas no sistema

em estudo, fazendo com que se tenha uma estimativa da redução da demanda em função destas conectadas neste sistema.

6.3 PUBLICAÇÕES

Durante o período do Mestrado, foram publicados os seguintes trabalhos:

1. MILKE, T. F.; ABAIDE, A. R.; BERNARDON, D. P.; FUHRMANN, M. W.; SANTOS, M. M.; MIRANDA, S. T. Prediction and Demand Control Methodology for a Distribution System Using Artificial Neural Networks. The 7th International Conference on Modern Power Systems (MPS 2017), Cluj-Napoca, Romênia, Jun. 2017.
2. MILKE, T. F.; ABAIDE, A. R.; Redes neurais artificiais aplicadas como metodologia de previsão de demanda e controle da energia elétrica contratada no mercado para um sistema de distribuição. XI CBPE – Congresso Brasileiro de Planejamento Energético, Cuiabá, Brasil, Set. 2018.

REFERÊNCIAS

- ALONSO, R.; CHÁVEZ, A. Short Term Load Forecast Method Using Artificial Neural Network With Artificial Immune Systems. **2017 IEEE URUCON**, Montevideo, Oct. 2017. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8171844>>. Acesso em: 3 jul. 2019. DOI: 10.1109/URUCON.2017.8171844.
- ALTRAN, A. B. **Sistema Inteligente para Previsão de Carga Multinodal em Sistemas Elétricos de Potência**. 2010. 87 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, SP, 2010.
- ALVES, M. F. **Previsão de Cargas não Residenciais Mistas por Redes Neurais ARTMAP FUZZY**. 2019. 86 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, SP, 2019.
- ANTUNES, J. F. **Previsão de Carga Multinodal Usando Rede Neural ART-ARTMAP FUZZY**. 2013. 101 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, SP, 2013.
- DE ANDRADE, L. C. M.; DA SILVA, I. N. Efficient Neurofuzzy Model to Very Short-Term Load Forecasting. **IEEE Latin America Transactions**, v. 14, n. 2, Feb. 2016. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7437215>>. Acesso em: 18 jun. 2019. DOI: 10.1109/TLA.2016.7437215.
- BARRETO, M. N. **Análise e previsão de carga crítica ativa e reativa do Sistema Elétrico Brasileiro**. 2017. 158 f. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas - Faculdade de Engenharia Elétrica e de Computação, Campinas, SP, 2017.
- BENTO, P. M. R.; POMBO, J. A. N.; CALADO, M. R. A.; MARIANO, S. J. P. S. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting. **Elsevier Neurocomputing**, v. 358, May 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925231219306927>>. Acesso em: 2 mar. 2019. DOI: 10.1016/j.neucom.2019.05.030.
- BOU, A. S. F.; FERREIRA, V. H. Previsão de Carga Elétrica no Curto Prazo com Redes Neurais. **Engevista**, v. 16, n. 1, p. 91-101, Mar. 2014.
- CARCEDO, J. M.; GARCÍA, J. P. Time of day effects of temperature and daylight on short term electricity load. **Elsevier Energy**, v. 174, May 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544219303573>>. Acesso em: 21 mar. 2019. DOI: 10.1016/j.energy.2019.02.158.
- CARMONA, D.; JARAMILLO, M. A.; GONZALEZ, E.; ALVETEZ, J. A. Electric energy demand forecasting with neural networks. 28th Annual Conference of the Industrial Electronics Society. **IECON 2002**, Sevilla, Spain, Nov. 2002. 2 jul.
- COSTA, C. I. A. **Aplicação de técnicas de big data à previsão de carga elétrica**. 2017. 179 f. Tese (Doutorado em Engenharia Elétrica), Universidade Federal de Itajubá, Itajubá, MG, 2017.

CASAGRANDE, G. F.; ANDO JUNIOR, O. H.; OLIVEIRA, M. O.; PERRONE, O. E.; REVERSAT, J. H. Very Short-Term Electric Load Forecasting Considering Climate and Temporal Variable. **International Journal of Automation and Power Engineering (IJAPE)**, v. 3, Jan. 2016. Disponível em: <<https://www.researchgate.net/publication/270559365>>. Acesso em: 15 jul. 2019. DOI: 10.14355/ijape.2014.0301.02.

CHANDRAMITASARI, W.; KURNIAWAN, B.; FUJIMURA, S. Building Deep Neural Network Model for Short Term Electricity Consumption Forecasting. **2018 International Symposium on Advanced Intelligent Informatics (SAIN)**, Yogyakarta, Indonesia, Aug. 2018.

CHEMETOVA, S. R. **Previsão de consumo de energia eléctrica nos principais Pontos injectores da rede de transporte na rede de distribuição**. 2018, 188 f. Tese (Doutorado em Engenharia Electrotécnica e Computadores) – Universidade Nova de Lisboa, Lisboa, 2018.

CHEN, K.; CHEN, K.; WANG, Q.; HE, Z.; HU, J.; HE, J. Short-Term Load Forecasting With Deep Residual Networks. **IEEE Transactions on Smart Grid**, v. 10, n. 4, July 2019. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8372953&tag=1>>. Acesso em: 23 mar. 2019. DOI: 10.1109/TSG.2018.2844307

DA SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: fundamentos teóricos e aspectos práticos. **Artliber**, 2ª edição, São Paulo, 2016.

DE MACEDO, M. N. Q. **Classificação automática das curvas de cargas usando RNA no ambiente smart grid**. 2014. 87f. Tese (Doutorado em Engenharia Industrial) - Universidade da Bahia, Salvador, 2014.

DODOMANI, S. N.; SHETTY, V. J.; MAGADUM, R.B. Short Term Load Forecast Based on Time Series Analysis: A Case Study, 2015. **International Conference on Technological Advancements in Power and Energy (TAP Energy)**. Kollam, India, Jun. 2015.

DUDEK, G. Ensembles of general regression neural networks for short-term electricity demand forecasting. **18th International Scientific Conference on Electric Power Engineering (EPE)**. Kouty nad Desnou, Czech Republic, May 2017.

EPE – Empresa de Pesquisa Energética. **Anuário Estatístico de Energia Elétrica**, 2018.

ELJAZZAR, M. M.; HEMAYED, E. E. Feature selection and optimization of artificial neural network for short term load forecasting. 2016. **Eighteenth International Middle East Power Systems Conference (MEPCON)**, Cairo, Egypt, Dec. 2016.

FERNANDES, R. A. S. **Identificação de Fontes de Corrente Harmônicas por Redes Neurais Artificiais**. 2009. 127 p. Dissertação (Mestrado em Engenharia Elétrica) – Escola de Engenharia de São Carlos - Universidade de São Paulo, São Carlo, 2009.

GASTALDELLO, D. S. **Desenvolvimento de metodologia para previsão de demanda de energia eléctrica residencial considerando aspectos socioeconômicos e ferramentas**

computacionais inteligentes. Tese de Doutorado – Escola Politécnica da Universidade de São Paulo, São Paulo, SP, 2017.

GUIRELLI, C. R. **Previsão no Curto Prazo de Áreas Elétricas Através de Técnicas de Inteligência Artificial.** 2006. 127 f. Tese (Doutorado em Engenharia Elétrica) – Escola Politécnica da Universidade de São Paulo, São Paulo, SP, 2006.

HAYKIN, S. Redes neurais: princípios e prática. **Bookman**, 2ª ed., Porto Alegre, 2001.

KOHLER, M. R. **Redes Neurais Aplicadas à Construção de Aproximadores para Simulação Integrada entre Reservatório e Sistema de Produção.** 2013. 96 p. Dissertação (Mestrado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2013.

KONG, W. ,DONG, Z. Y.; HILL, D. J.; LUO, F.; XU, Y. Short-Term Residential Load Forecasting Based on Resident Behaviour Learning. **IEEE Transactions on Power Systems**, v. 33, n. 1, Jan. 2018. Disponível em: < <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7887751> >. Acesso em: 22 mar. 2019. DOI: 10.1109/TPWRS.2017.2688178.

KUO, W.; HSIEH, T., CHEN, H.; CHI, C.; HUANG, Y. A Novel Framework Short-Term Load Forecasting for Micro-grid Energy Management System. **6th IEEE International Conference on Smart Energy Grid Engineering**, p. 279-283, Oshawa, Canada, Aug. 2018.

LIANG, Y.; NIU, D.; HONG, W. Short term load forecasting based on feature extraction and improved general regression neural network model. **Elsevier Energy**, v. 166, 2019. Disponível em: < <https://www.sciencedirect.com/science/article/pii/S0360544218321091> >. Acesso em: 25 mar. 2019. DOI: 10.1016/j.energy.2018.10.119.

LIU, C.; JIN, Z.; GU, J.; QIU, C. Short-term load forecasting using a long short-term memory network. **IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)**, Torino, Italy, Sept. 2017.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biology**, v. 52, p. 99-115, 1943.

MILKE, T. F.; ABAIDE, A. R.; BERNARDON, D. P.; FUHRMANN, M. W.; SANTOS, M. M.; MIRANDA, S. T. Prediction and Demand Control Methodology for a Distribution System Using Artificial Neural Networks. **The 7th International Conference on Modern Power Systems (MPS 2017)**, Cluj-Napoca, Romania, Jun. 2017.

MOREIRA, M. O. **Um Estudo de Caso para a Previsão de Carga de Médio e Longo Prazo Brasileira.** 2015. 194 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, 2015.

MUZAFFAR, S.; AFSHARI, A. Short-Term Load Forecasting Using LSTM Networks. **10th International Conference on Applied Energy (ICAE2018)**, Hong Kong, China, Aug. 2018.

NARAYAN, A.; HIPEL, K. W. Long Short Term Memory Networks for Short-Term Electric Load Forecasting. **IEEE International Conference on Systems, Man, and Cybernetics (SMC)**, Canada, Oct. 2017.

NICHIFOROV, C.; STAMATESCU, I.; FAGARASAN, I.; STAMATESCU, G. Energy consumption forecasting using ARIMA and neural network models. **5th International Symposium on Electrical and Electronics Engineering (ISEEE)**, Galati, Romania, Oct. 2017.

NEUSSER, L. **Combinação Seletiva de Métodos para Previsão de Demanda a Curtíssimo Prazo em Tempo Real**. 2015. 131 f. Tese (Tese de Doutorado em Engenharia Elétrica) - Universidade Federal de Santa Maria, Santa Maria, 2015.

NIGITZ, T.; GÖLLES, M. A generally applicable, simple and adaptive forecasting method for the short-term heat load of consumers. **Applied Energy**, v. 241, 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306261919304039>>. Acesso em: 25 mar. 2019. DOI: 10.1016/j.apenergy.2019.03.012.

PANDEY, A. K.; SAHAY, K. B.; TRIPATHI, M. M.; CHANDRA, D. Short-term load forecasting of UPPCL using ANN. **6th IEEE Power India International Conference (PIICON)**, Delhi, India, Dec. 2014.

PHATAI, G.; CHIEWCHANWATTANA, S.; SUNAT, K. A Comparative of Neural Network with Metaheuristics for Electricity Consumption Forecast Modelling. **22nd International Computer Science and Engineering Conference (ICSEC)**. Chiang Mai, Thailand, Nov. 2018.

REJC, M.; PANTOS, M. Short-Term Transmission-Loss Forecast for the Slovenian Transmission Power System Based on a Fuzzy-Logic Decision Approach. **IEEE Transactions on Power Systems**, v. 26, Aug. 2011. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5685606>>. Acesso em: 01 jun. 2019. DOI: 10.1109/TPWRS.2010.2096829.

ROMERA, E. G.; MORÁN, M. A. J.; FERNÁNDEZ, D. C. Monthly electric energy demand forecasting based on trend extraction. **IEEE Transactions on Power Systems**, v. 21, n.4, Nov. 2006. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1717600>>. Acesso em: 02 jun. 2019. DOI: 10.1109/TPWRS.2006.883666

SAVIOZZI, M.; SILVESTRO, M. F. Implementation of advanced functionalities for Distribution Management Systems: Load forecasting and modeling through Artificial Neural Networks ensembles. **Electric Power Systems Research**, v. 167, 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779618303596>>. Acesso em: 3 jun. 2019. DOI: 10.1016/j.epr.2018.10.036.

SERRANO-GUERRERO, X.; PRIETO-GALARZA, R.; HUILCATANDA, E.; CABRERA-ZEAS, J.; ESCRIVÁ-ESCRIVÁ, G. Election of Variables and Short-term Forecasting of Electricity Demand Based on Backpropagation Artificial Neural Networks. **IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC 2017)**. Ixtapa, Mexico, Nov. 2017.

SINGH, N. K.; SINGH, A. K.; PALIWAL, N. Neural Network based short-term electricity demand forecast for Australian states. **IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)**. Delhi, India, July. 2016.

SHINGH, A.; SAHAY, K. B. Short-Term Demand Forecasting By Using ANN Algorithms. **IEECON 2018**, Krabi, Thailand, Mar. 2018.

SILVA, L. N.; ABAIDE, A. R.; NEGRI, V.G.; CAPELETTI, M.; LOPES, L. F.; CARDOSO, G. Diagnostic and Input Selection Tool applied on Weather Variables for Studies of Short-Term Load Forecasting. **8th International Conference on Modern Power Systems (MPS)**, Cluj Napoca, Romênia, 2019.

SILVA, L. N.; ABAIDE, A. R.; FIGUEIRÓ, I. C.; MARTINUZZI, D.; RIGODANZO, J. Development of an ANN Model to Multi-Region Short- Term Load Forecasting based on Power Demand Patterns Recognition. **IEEE PES Innovative Smart Grid Technologies Conference – Latin America (ISGT Latin America)**. Quito, Ecuador, 2017a.

SILVA, L. N.; ABAIDE, A. R.; FIGUEIRÓ, I. C.; SILVA, J. O.; RIGODANZO, J.; SAUSEN, J. P. Development of Brazilian Multi Region Short-Term Load Forecasting Model Considering Climate Variables Weighting in ANN Model. **52 nd International Universities Power Engineering Conference (UPEC)**. Heraklion, Greece, 2017b.

WARRIOR, K. P.; SHRENIK, M.; SONI, N. Short-term electrical load forecasting using predictive machine learning models. **IEEE Annual India Conference (INDICON)**, Bangalore, India, Dec. 2016.

WERON, R. Electricity Price Forecasting: A review of the state-of-the-art with a look into the future. **International Journal of Forecasting**, v. 30, Dec., 2014. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169207014001083>>. Acesso em: 3 jul. 2019. DOI: 10.1016/j.ijforecast.2014.08.008.

XIE, K.; YI, H.; HU, G.; LI, L.; FAN, Z. Short-Term Power Load Forecasting Based on Elman Neural Network with Particle Swarm Optimization. **Elsevier Neurocomputing**, Feb. 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925231219308756?via%3Dihub>>. Acesso em: 4 jun. 2019. DOI:

XU, Y.; CAI, J.; MILANOVIĆ, J. V. On accuracy of demand forecasting and its extension to demand composition forecasting using artificial intelligence based methods. **IEEE PES Innovative Smart Grid Technologies**, Istanbul, Turkey, Oct. 2014.

YAHYA, M. A.; HADI, S. P.; PUTRANTO, L. M. Short-term electric load forecasting using Recurrent Neural Network (study case of load forecasting in central java and special region of Yogyakarta). **4th International Conference on Science and Technology (ICST)**, Yogyakarta, Indonesia, 2018.