


**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
CAMPUS DE ILHA SOLTEIRA**

GLEISON DA SILVA GUILHERMITE

**ESTUDO DA REDE NEURAL NARX POR MEIO DA VARIAÇÃO DE
PARÂMETROS E DOS DADOS HISTÓRICOS DE CARGA ELÉTRICA NA
PREVISÃO DE DEMANDA**



Ilha Solteira - SP
2025

PROGRAMA DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

GLEISON DA SILVA GUILHERMITE

ESTUDO DA REDE NEURAL NARX POR MEIO DA VARIAÇÃO DE PARÂMETROS E DOS DADOS HISTÓRICOS DE CARGA ELÉTRICA NA PREVISÃO DE DEMANDA

Trabalho de Conclusão de Curso
apresentado à Universidade Estadual
Paulista (UNESP), Júlio de Mesquita Filho,
Ilha Solteira/SP, para obtenção do título de
Bacharel em Engenharia Elétrica.

Área de Concentração: Engenharia
Elétrica

Orientadora: Prof. Dra. Mara Lucia Martins
Lopes

Ilha Solteira - SP

2025

FICHA CATALOGRÁFICA
Desenvolvida pela Diretoria Técnica de Biblioteca e Documentação

G956e Guilhermite, Gleison da Silva.
Estudo da rede neural NARX por meio da variação de parâmetros e dos dados históricos de carga elétrica na previsão de demanda / Gleison da Silva Guilhermite. -- Ilha Solteira: [s.n.], 2025
123 f. : il.

Trabalho de conclusão de curso (Graduação em Engenharia Elétrica) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2025

Orientadora: Mara Lucia Martins Lopes
Inclui bibliografia

1. Smart-grids. 2. Previsão. 3. Demanda de carga. 4. NARX.

IMPACTO POTENCIAL DESTA PESQUISA

Ampliar o escopo de aplicações e investigar os possíveis potenciais da rede neural NARX na previsão de cargas elétricas de sistemas de potência, para o auxílio de atendimento à demanda em tempo real, garantindo o fornecimento contínuo e de qualidade de energia elétrica.

POTENTIAL IMPACT OF THIS RESEARCH

Expand the scope of applications and investigate the potential of the NARX neural network in forecasting electrical loads of power systems, to help meet demand in real time, ensuring the continuous and quality supply of electrical energy.

ATA DE DEFESA DE TRABALHO DE GRADUAÇÃO

Aos cinco do mês de dezembro do ano de dois mil e vinte e cinco, o discente *Gleison da Silva Guilhermite*, matriculado sob o nº 201054124, tendo como banca examinadora a sua orientadora, a Profª. Drª. Mara Lúcia Martins Lopes, o Doutorando Haislan Panelli Santana Bernardes e o Doutorando Reginaldo José da Silva, apresentou o Trabalho de Graduação do Curso de Engenharia Elétrica (FEIS-UNESP) intitulado "Estudo da Rede Neural NARX através da Variação de Parâmetros e dos Dados Históricos de Carga Elétrica na Previsão de Demanda", obtendo a nota

99 (noventa e nove) e conceito APROVADO.



Gleison da Silva Guilhermite

- discente -



Profª. Drª. Mara Lúcia Martins Lopes

- orientadora -



Doutorando Haislan Panelli Santana Bernardes

- Membro da Banca -



Doutorando Reginaldo José da Silva

- Membro da Banca -

Dedico este trabalho à minha família, por todo o apoio e incentivo ao longo de minha
jornada acadêmica.

Aos meus amigos, por sempre me motivarem a seguir em frente não importando os
obstáculos no caminho.

A Deus, em especial, por sempre cuidar de mim, principalmente nas horas mais
difíceis da vida, e por colocar pessoas maravilhosas para me guiar.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da UNESP – Júlio de Mesquita Filho, Ilha Solteira/SP, com o fornecimento da licença do Matlab.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio financeiro, concedido por meio do Processo nº 2024/16370-6.

À professora Dra. Mara, pelo acompanhamento em todo o processo da pesquisa e incentivo à ciência.

“O que prevemos raramente ocorre; o que
menos esperamos geralmente acontece.”
(Benjamin Disraeli)

RESUMO

No contexto de grandes inovações e integração do sistema elétrico no Brasil, as *Smart Grids* (Redes Inteligentes) trazem maior controle, inovação tecnológica, eficiência e confiabilidade, principalmente por meio da previsão da curva de demanda da carga. A previsão permite obter maior controle e eficiência energética, evitando encargos na rede e melhor preparação para demanda de energia, sendo possível pelo uso de Redes Neurais Artificiais (RNAs). Existem muitas arquiteturas para obter a previsibilidade da carga elétrica, sendo uma delas a NARX (*Nonlinear Autoregressive Exogenous*). Esta pesquisa tem como objetivo realizar a previsão do perfil de carga de uma rede de consumidores com o uso dos dados fornecidos pela empresa distribuidora de energia elétrica LIGHT, para valores de potências diárias de consumidores residenciais e comerciais da cidade do Rio de Janeiro. Para tal, é utilizada a Toolbox do Matlab de redes neurais com a realização da arquitetura com base no modelo NARX, analisando os resultados pela variação dos parâmetros da rede e a influência dos feriados nacionais e estações do ano na alteração da demanda. Analisando diferentes resultados para previsões de um a três dias, por meio da alteração do período usado como amostras de entrada e dos parâmetros e arquitetura da rede, obtiveram-se resultados (principalmente para as previsões dos dias de Natal, Tiradentes e Nossa Senhora Aparecida) com erros percentuais médios absolutos (MAPE) na maioria menores do que 1%, com erros máximos variando na faixa de 0,5% a 10% na maior parte dos casos estudados.

Palavras-chave: *Smart-grids*; Previsão; Demanda de carga; NARX.

ABSTRACT

In the context of major innovations and integration of the electrical system in Brazil, Smart Grids bring greater control, technological innovation, efficiency, and reliability, mainly through the forecasting of the load demand curve. Forecasting allows for greater control and energy efficiency, avoiding network charges and better preparing for energy demand, making it possible using Artificial Neural Networks (ANNs). Many architectures exist for achieving electrical load predictability, one of which is NARX (Nonlinear Autoregressive Exogenous). This research aims to forecast the load profile of a consumer network using data provided by the electricity distribution company LIGHT, for daily power values of residential and commercial consumers in the city of Rio de Janeiro. To this end, the Matlab Neural Network Toolbox is used, implementing the architecture based on the NARX model, analyzing the results by the variation of network parameters and the influence of national holidays and seasons on demand changes. Analyzing different results for one- to three-day forecasts, by altering the period used as input samples and the network parameters and architecture, results were obtained (mainly for forecasts for Christmas, Tiradentes Day, and Our Lady of Aparecida Day) with mean absolute percentage errors (MAPE) mostly less than 1%, with maximum errors ranging from 0.5% to 10% in most of the cases studied.

Keywords: *Smart grids*; Forecasting; Load demand; NARX.

LISTA DE FIGURAS

Figura 1 - Estrutura do Neurônio artificial.....	23
Figura 2 - Conceito do neurônio artificial baseado no neurônio biológico.	23
Figura 3 - Estrutura de uma RNA composta de um único neurônio artificial.	25
Figura 4 - Principais tipos de funções de ativação.	26
Figura 5 - Estrutura geral da arquitetura da rede NARX.	29
Figura 6 - Estrutura da rede NARX com enfoque nas entradas e saídas.....	32
Figura 7 - Rede NARX em malhas aberta e fechada.	32
Figura 8 - Rede NARX estruturada do ponto de vista de uma MLP.	34
Figura 9 - Descrição detalhada do funcionamento e estrutura da rede NARX.	38
Figura 10 - Diagrama de blocos da estrutura da rede NARX.	41
Figura 11 - Organização original dos dados.....	42
Figura 12 - Visualização gráfica dos resultados apresentados pela toolbox.	43
Figura 13 - Interface interativa de abertura da toolbox do Matlab.	44
Figura 14 - Seleção do tipo de rede neural a ser utilizada para análise dos dados. .	44
Figura 15 - Seleção dos dados de entrada da rede neural.	45
Figura 16 - Estrutura disponibilizada pelo toolbox da rede construída.	46
Figura 17 - Funcionamento da etapa de treinamento da rede pela toolbox.	46
Figura 18 - Opções de gráficos disponibilizados sobre a rede NARX.	47
Figura 19 - Fluxograma do filtro de dados de entrada da rede NARX (parte 1).	49
Figura 20 - Fluxograma do filtro de dados de entrada da rede NARX (parte 2).	50
Figura 21 - Previsão para o dia 1 de fevereiro utilizando o mês de janeiro.....	52
Figura 22 - Previsão para o dia 1 de março utilizando o mês de fevereiro.....	53
Figura 23 - Previsão para o dia 1 de abril utilizando o mês de março.....	54
Figura 24 - Predição para o dia 1 de abril utilizando o primeiro trimestre de 1998....	55
Figura 25 - Resultado das predições para o dia 14 de outubro antes da correção. ..	56
Figura 26 - Resultado das predições para o dia 14 de outubro após a correção.	57
Figura 27 - Previsão do Natal em um dia e um mês de amostra.....	59
Figura 28 - Previsão do Natal em dois dias e um mês de amostra.	60
Figura 29 - Previsão do Natal em três dias e um mês de amostra.....	60
Figura 30 - Previsão do Natal em um dia e dois meses de amostra.	61
Figura 31 - Previsão do Natal em dois dias e dois meses de amostra.....	61
Figura 32 - Previsão do Natal em três dias e dois meses de amostra.	62

Figura 33 - Previsão do Natal em um dia e três meses de amostra.....	62
Figura 34 - Previsão do Natal em dois dias e três meses de amostra.	63
Figura 35 - Previsão do Natal em três dias e três meses de amostra.	63
Figura 36 - Previsão para Tiradentes em um dia e 15% validação.	65
Figura 37 - Previsão para Tiradentes em dois dias e 15% validação.....	66
Figura 38 - Previsão para Tiradentes em três dias e 15% validação.	66
Figura 39 - Previsão para Tiradentes em um dia e 10% validação.	67
Figura 40 - Previsão para Tiradentes em dois dias e 10% validação.....	67
Figura 41 - Previsão para Tiradentes em três dias e 10% validação.	68
Figura 42 - Previsão para Tiradentes em um dia e 5% validação.	68
Figura 43 - Previsão para Tiradentes em dois dias e 5% validação.....	69
Figura 44 - Previsão para Tiradentes em três dias e 5% validação.	69
Figura 45 - Previsão para N. S. Aparecida em um dia.	71
Figura 46 - Previsão para N. S. Aparecida em dois dias.....	72
Figura 47 - Previsão para N. S. Aparecida em três dias.	72
Figura 48 - Erro para a previsão de carga do primeiro dia de fevereiro.	87
Figura 49 - Erro para a previsão de carga do primeiro dia de março.	87
Figura 50 - Erro para a previsão de carga do primeiro dia de abril.	88
Figura 51 - Erro para a previsão de carga do primeiro dia de abril (usando 3 meses).	88
Figura 52 - Predição da carga para o dia 14 de outubro em tempo real.	89
Figura 53 - Erro para a previsão da carga de 14 de outubro.....	89
Figura 54 - Erro para a previsão de carga no Natal (1 dia, 1 mês).....	90
Figura 55 - Predição da carga para o dia 25 de dezembro (1 dia, 1 mês).	90
Figura 56 - Erro para a previsão de carga no Natal (1 dia, 2 meses).....	91
Figura 57 - Predição da carga para o dia 25 de dezembro (1 dia, 2 meses).....	91
Figura 58 - Erro para a previsão de carga no Natal (1 dia, 3 meses).....	92
Figura 59 - Predição da carga para o dia 25 de dezembro (1 dia, 3 meses).....	92
Figura 60 - Erro para a previsão de carga no Natal (2 dias, 1 mês).....	93
Figura 61 - Predição da carga para o dia 25 de dezembro (2 dias, 1 mês).....	93
Figura 62 - Erro para a previsão de carga no Natal (2 dias, 2 meses).	94
Figura 63 - Predição da carga para o dia 25 de dezembro (2 dias, 2 meses).	94
Figura 64 - Erro para a previsão de carga no Natal (2 dias, 3 meses).	95
Figura 65 - Predição da carga para o dia 25 de dezembro (2 dias, 3 meses).	95

Figura 66 - Erro para a previsão de carga no Natal (3 dias, 1 mês).....	96
Figura 67 - Predição da carga para o dia 25 de dezembro (3 dias, 1 mês).....	96
Figura 68 - Erro para a previsão de carga no Natal (3 dias, 2 meses).....	97
Figura 69 - Predição da carga para o dia 25 de dezembro (3 dias, 2 meses).....	97
Figura 70 - Erro para a previsão de carga no Natal (3 dias, 3 meses).....	98
Figura 71 - Predição da carga para o dia 25 de dezembro (3 dias, 3 meses).....	98
Figura 72 - Erro para a previsão de carga de Tiradentes (1 dia, 70%).....	99
Figura 73 - Predição da carga para o dia 21 de abril (1 dia, 70%).	99
Figura 74 - Erro para a previsão de carga de Tiradentes (1 dia, 80%).....	100
Figura 75 - Predição da carga para o dia 21 de abril (1 dia, 80%).	100
Figura 76 - Erro para a previsão de carga de Tiradentes (1 dia, 90%).....	101
Figura 77 - Predição da carga para o dia 21 de abril (1 dia, 90%).	101
Figura 78 - Erro para a previsão de carga de Tiradentes (2 dias, 70%).....	102
Figura 79 - Predição da carga para o dia 21 de abril (2 dias, 70%).	102
Figura 80 - Erro para a previsão de carga de Tiradentes (2 dias, 80%).....	103
Figura 81 - Predição da carga para o dia 21 de abril (2 dias, 80%).	103
Figura 82 - Erro para a previsão de carga de Tiradentes (2 dias, 90%).....	104
Figura 83 - Predição da carga para o dia 21 de abril (2 dias, 90%).	104
Figura 84 - Erro para a previsão de carga de Tiradentes (3 dias, 70%).....	105
Figura 85 - Predição da carga para o dia 21 de abril (3 dias, 70%).	105
Figura 86 - Erro para a previsão de carga de Tiradentes (3 dias, 80%).....	106
Figura 87 - Predição da carga para o dia 21 de abril (3 dias, 80%).	106
Figura 88 - Erro para a previsão de carga de Tiradentes (3 dias, 90%).....	107
Figura 89 - Predição da carga para o dia 21 de abril (3 dias, 90%).	107
Figura 90 - Erro para a previsão de carga de N. S. Aparecida (1 dia, 1 mês).....	108
Figura 91 - Predição da carga para o dia de N. S. Aparecida (1 dia, 1 mês).	108
Figura 92 - Erro para a previsão de carga de N. S. Aparecida (1 dia, 2 meses).	109
Figura 93 - Predição da carga para o dia de N. S. Aparecida (1 dia, 2 meses).....	109
Figura 94 - Erro para a previsão de carga de N. S. Aparecida (1 dia, 3 meses).	110
Figura 95 - Predição da carga para o dia de N. S. Aparecida (1 dia, 3 meses).....	110
Figura 96 - Erro para a previsão de carga de N. S. Aparecida (2 dias, 1 mês).	111
Figura 97 - Predição da carga para o dia de N. S. Aparecida (2 dias, 1 mês).....	111
Figura 98 - Erro para a previsão de carga de N. S. Aparecida (2 dias, 2 meses). ..	112
Figura 99 - Predição da carga para o dia de N. S. Aparecida (2 dias, 2 meses).....	112

Figura 100 - Erro para a previsão de carga de N. S. Aparecida (2 dias, 3 meses).	113
Figura 101 - Predição da carga para o dia de N. S. Aparecida (2 dias, 3 meses)...	113
Figura 102 - Erro para a previsão de carga de N. S. Aparecida (3 dias, 1 mês).	114
Figura 103 - Predição da carga para o dia de N. S. Aparecida (3 dias, 1 mês).....	114
Figura 104 - Erro para a previsão de carga de N. S. Aparecida (3 dias, 2 meses).	115
Figura 105 - Predição da carga para o dia de N. S. Aparecida (3 dias, 2 meses)...	115
Figura 106 - Erro para a previsão de carga de N. S. Aparecida (3 dias, 3 meses).	116
Figura 107 - Predição da carga para o dia de N. S. Aparecida (3 dias, 3 meses)...	116
Figura 108 – Dias da semana em análise para janeiro.	117
Figura 109 – Dias da semana para análise em fevereiro.	118
Figura 110 – Dias da semana em análise para março.	118

LISTA DE TABELAS

Tabela 1 - Resultados para a alteração de métodos de cálculo de erro.	58
Tabela 2 - Resultados para a alteração do período amostral.....	64
Tabela 3 - Resultados para as previsões do feriado de Tiradentes.	70
Tabela 4 - Resultados para as previsões do feriado de N.S. Aparecida.	72
Tabela 5 - Resultados resumidos para as previsões dos feriados estudados.....	73

LISTA DE QUADROS

Quadro 1 - Comparação entre os modelos neurais e estatísticos.....	22
--	----

LISTA DE ABREVIATURAS E SIGLAS

SEP	Sistema Elétrico de Potência
ANEEL	Agência Nacional de Energia Elétrica
UE	União Europeia
IC	Inteligência Computacional
RNA	Rede Neural Artificial
MLP	<i>Multi-Layer Perceptron</i>
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
ARMA	<i>Autoregressive Moving Average</i>
NARX	<i>Nonlinear Autoregressive Exogenous</i>
RNN	<i>Recurrent Neural Network</i>
EQM	Erro Quadrático Médio
MSE	<i>Mean Square Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
RMSE	<i>Root Mean Square Error</i>
DMA	Desvio Médio Absoluto
ADALINE	<i>Adaptative Linear Element</i>

LISTA DE SÍMBOLOS

$E_{\max}$	Erro máximo
$E_{\min}$	Erro mínimo

SUMÁRIO

1	INTRODUÇÃO	16
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	SMART GRIDS.....	20
2.2	REDES NEURAIS ARTIFICIAIS.....	21
2.3	REDE NEURAL NARX	28
3	OBJETIVOS	40
4	MATERIAL E MÉTODOS	41
5	RESULTADOS E DISCUSSÕES	52
6	CONCLUSÃO	75
	REFERÊNCIAS.....	77
	ANEXO – MATRIZ DE DADOS DE CARGA	80
	APÊNDICE A – DEMAIS GRÁFICOS PARA OS RESULTADOS	
	APRESENTADOS DE CADA CASO ESTUDADO	87
	APÊNDICE B – ANÁLISE DOS PERÍODOS AMOSTRAIS ESCOLHIDOS	
	PARA ENTRADA NA REDE NARX (CONSIDERANDO DIA DA SEMANA	
	E ESTAÇÃO DO ANO NO PRIMEIRO TRIMESTRE)	117

1 INTRODUÇÃO

No Sistema Elétrico de Potência (SEP), através da ANEEL (Agência Nacional de Energia Elétrica), é buscado a cada dia garantir o seu funcionamento seguro e confiável, lidando com um volume cada vez mais crescente de informações acerca de dados de potência, tensão e corrente, por exemplo, no objetivo de obter maior eficiência, disponibilidade e confiabilidade na energia elétrica. Por esta razão, é necessária maior sistematização, de forma a atender tarefas complexas nas áreas de planejamento, operação e administração, exigindo ferramentas computacionais mais poderosas (KOPILER et al, 2019). Para o SEP apresentar confiabilidade e economia nas suas operações, é indispensável o uso de previsões de carga no horizonte de extremo curto prazo. Conforme apontado por Andrade (2014), “Um dos objetivos fundamentais do sistema de controle é manter o equilíbrio entre demanda e fornecimento de eletricidade”.

Em um contexto em que o consumo global de energia cresce a cada dia, a sua gestão de geração e fornecimento, bem como no desenvolvimento de novos modelos de negócio, assumiram grande importância (ZUAZO, 2021). A eletricidade, se comparada às demais fontes de energia convencionais, como carvão, gás e combustível, se tornou uma parte inerente do cotidiano da população e fundamental em importantes setores da economia, como por exemplo no setor de transportes. O consumo de eletricidade vem crescendo a um ritmo cada vez mais acelerado, maior do que o crescimento da população, onde tal crescimento indica uma necessidade de melhoria no sistema elétrico, através do correto planejamento que somente será possível por um ajuste preciso entre geração e consumo (ZUAZO, 2021). Um exemplo que demonstra este cenário está na UE (União Europeia), com mais de 40% do consumo de energia estando concentrado principalmente em edificações, sendo um dos desafios mais importantes que os fornecedores devem enfrentar na procura de respostas e soluções para atendimento a essa demanda (ZUAZO, 2021, p. 1).

Dentre as metodologias adotadas para ajuste entre demanda e geração de energia, estão as previsões de carga, onde há a criação de modelos que simulem a curva de demanda de carga elétrica em diferentes pontos de consumo do SEP, a ocorrência de falhas e a recorrente utilização de dados sob influência destas falhas afetam de forma direta na precisão das previsões, causando impactos significativos na qualidade dos resultados.

Em uma definição mais elaborada, pode-se assumir que a qualidade de energia elétrica envolve o estudo das variações em regime permanente que provocam o desequilíbrio dos sinais de tensão ou de corrente causadas por falhas na rede elétrica. Por esta razão, há um crescente fluxo de dados em sistemas de energia, com estudos desses fenômenos iniciados na década de 90, pela crescente introdução de cargas não lineares na malha elétrica. Tais falhas, na perspectiva de previsão de cargas, devem ser devidamente estudadas, para evitar a introdução de dados que prejudiquem a continuidade das previsões, considerando-se apenas informações da rede em regime permanente e em correto funcionamento. Conforme apontado por Alcântara (2020, p. 14):

[...] foram caracterizados distúrbios elétricos como as elevações (swells) e afundamentos (sags) de tensão, harmônicos, inter-harmônicos, interrupções, transientes, notches, entre outros, tais como supra harmônicos e flickers, que vem surgindo com o crescimento e a diversificação de equipamentos nos atuais sistemas elétricos. (2020, p. 14 apud WARD et al., 1990, BOARD, 1995, COMMUNICATION, 1990)

Com relação às causas destes distúrbios, podem ser mencionadas as fontes chaveadas, as descargas atmosféricas, a sobrecarga de equipamentos ligados simultaneamente, o chaveamento de banco de capacitores, curtos-circuitos, má operação da rede e o uso de fontes de geração distribuída, causando como consequência a baixa qualidade de energia elétrica e danos financeiros.

Dentre os prejuízos causados por falhas elétricas, podem ser citados como exemplos mais recorrentes: a queima de circuitos eletrônicos, inoperância de equipamentos, perda do conjugado de motores, decaimento do fator de potência, aquecimento de condutores e a queima de fusíveis e peças de computadores. Para contornar estes problemas, passou-se a adotar redes inteligentes integradas ao sistema elétrico de potência, denominadas Smart Grids, utilizando-se de ferramentas de Inteligência Computacional (IC) para a detecção de distúrbios na rede elétrica, usando sistemas de baixa complexidade computacional que permitem monitoramento em tempo real para aplicações de compensação e proteção.

Dentre as técnicas mais utilizadas em IC para a predição de cargas está o aprendizado de máquina, proporcionando “ganhos de tempo na identificação e solução de problemas, na realização de estudos, etc.; redução de erros humanos; disponibilização do conhecimento de técnicos experientes para todos os

operadores/engenheiros; automatização de procedimentos executados; entre outros” (KOPILER et al, 2019, p. 27). Um dos maiores desafios para técnicas de aprendizado de máquina, no entanto, está na crescente complexidade e constante mudança do SEP, exigindo algoritmos de aprendizagem contínua e capazes de lidar com um grande aumento na quantidade de informação, utilizando, por exemplo, técnicas de mineração de dados (KOPILER et al, 2019, p. 27).

Nas áreas de detecção de previsão de cargas, com relação aos processos executados atualmente em aprendizado de máquina, em primeiro lugar são extraídos os dados da rede através de um processo conhecido como janelamento (onde separa-se parte de um banco de dados completo como amostras para estudo), para destacar as diferenças entre os sinais nominais, e em seguida aplica-se um algoritmo de detecção de característica ou padrões comportamentais, geralmente por ciclos de onda (análise da janela de dados). Estes dados são então aplicados em algoritmos capazes de realizar previsões a curto, médio e longo prazo, permitindo maior controle e capacidade de preparo antecipado.

Diferentemente dos trabalhos de horizontes de previsão mais distantes, afetadas por fatores como clima e condições socioeconômicas (pois exercem influência na demanda por eletricidade), previsões de carga a extremo curto prazo requerem uma aproximação mais voltada à análise do comportamento atual das cargas (ANDRADE, 2014).

Em uma visão mais geral acerca da malha do SEP correlacionada a previsões de demanda, a rede elétrica integra muitas partes que compreendem desde a geração até a entrega de energia ao consumidor final, as quais podem ser afetadas diretamente por previsões imprecisas, uma vez que: a geração se utiliza de previsões de 24h a 48h para planejamento de suas operações, permitindo melhor administração dos recursos e do sistema; a transmissão possui dependência na alocação de recursos onde há necessidade, garantindo o acesso à energia elétrica em áreas de maior contingência; e os usuários se utilizam das previsões para calcular os custos de energia com base na demanda estimada para evitar perdas econômicas relacionadas a subdimensionamento ou superdimensionamento do sistema (BUIRAGO; ASFOUR, 2017).

Para se obter uma melhor visão dos impactos das previsões de carga sobre o SEP, as áreas mais diretamente influenciadas são as de: planejamento de contingência, redução de carga, e as de estratégias de gerenciamento e

comercialização de energia. Os erros nas previsões em cada uma destas atividades podem significar aumentos de custos significativos, sendo fundamental que métodos de previsão confiáveis sejam utilizados em fontes de agendamento e gerenciamento de carga para evitar maiores encargos (BUIRAGO; ASFOUR, 2017).

2 FUNDAMENTAÇÃO TEÓRICA

2.1 SMART GRIDS

As redes inteligentes, conhecidas como *smart grids*, são uma forma de integração de diferentes sistemas para maior controle do fluxo de informações em diferentes áreas, trabalhando com grandes conjuntos de bancos de dados pelo uso de ferramentas computacionais capazes de auxiliar na busca de soluções em diferentes tipos de problemas (OLATUNDE, 2024, p. 1259). São utilizadas, por exemplo, para melhor integração do sistema elétrico na geração, transmissão e consumo de energia, promovendo maior eficiência, confiabilidade e sustentabilidade (no sentido de evitar o uso desnecessário de recursos).

Através das *smart grids*, é possível ter o monitoramento em tempo real das informações e maior controle sobre as diversas variáveis do sistema (dados como uso do sistema, condições da rede e performance dos equipamentos), possibilitando vantagens como redução das perdas na transmissão e distribuição de energia (pelo apontamento de pontos ineficientes e de congestionamento de rede), integração de fontes de energia renováveis, implementação de programas de resposta a demanda, monitoramento e controle da rede em tempo real (através de medidores e sensores), melhor e mais rápida resposta a distúrbios na rede, previsão de possíveis anomalias e controle de demanda.

Todos os benefícios trazidos com o uso de *smart grids* se alinham à ideia de redução nos custos com os encargos que os sistemas convencionais apresentam, havendo maior integração dos elementos e resultando em melhor controle de dados, que podem ser feitos com o uso de inteligência artificial, devido à grande quantidade e volume de informações. Conforme um caso descrito por Olatunde (2024):

“A Ilha Jeju implementou um projeto de *smart grid* que integrou fontes de energia renováveis, tais como energia solar e eólica, na rede. O projeto reduziu a dependência da ilha em combustíveis fósseis, melhorou a eficiência energética, e melhorou a estabilidade da rede”. (OLATUNDE, 2024)

Para o caso apresentado, uma forma de se utilizar destes dados na solução de problemas está no uso das Redes Neurais Artificiais (RNAs), sendo uma das

ferramentas disponíveis para auxílio de tomada de decisões pelas informações extraídas de sistemas *smart grids*.

2.2 REDES NEURAIS ARTIFICIAIS

Uma Rede Neural Artificial (RNA) pode ser definida como um método matemático que busca realizar a simulação do processo de aquisição de conhecimento de um cérebro humano, onde sua aplicação tem apresentado sucesso ao estabelecer padrões comportamentais entre variáveis de entrada e saída, no reconhecimento de padrões, em problemas de classificação e de otimização (PEREIRA et al, 2018). Desta forma, possuem maior utilidade na resolução de problemas de diferentes naturezas, visto sua capacidade de discernimento e correlação de dados.

As RNAs são utilizadas em diversos campos de pesquisa, tais como: classificação e reconhecimento de padrões, aproximação de funções, processamento de imagens e de séries temporais, otimização e entre outras. Existem muitas vantagens no uso das RNAs (WERBOS, 1974), uma vez que, por sua capacidade em armazenar conhecimento, podem realizar operações de previsão de dados e reconhecimento de padrões por um processo de treinamento (NEVES et al, 2016, p. 2). Neste sentido, pode-se definir uma rede neural como sendo um processador massivo contendo inúmeras unidades simples em paralelo, capazes de armazenar conhecimento e disponibilizá-lo para uso (HAYKIN, 2001; NEVES et al, 2016).

As RNAs se assemelham ao cérebro em dois aspectos fundamentais: aquisição de conhecimento por estímulos externos (pelo ambiente) e aprendizagem, e armazenamento de informações nos pesos sinápticos (força de conexão neural). O processo de aprendizagem é realizado através de um algoritmo que realiza a alteração dos pesos sinápticos de maneira a adaptar a rede para alcançar o objetivo desejado.

As RNAs “vem se desenvolvendo desde 1943 com o início das pesquisas voltadas ao neurônio artificial de McCulloch & Pitts nessa mesma época, entretanto o termo inteligência artificial foi cunhado por John MacCarthy em 1956” (RUSSEL; NORVIG, 2009). Elas são eficazes no aprendizado de padrões a partir de dados com característica não linear, incompletos e que apresentam ruídos, com algumas de suas aplicações principais sendo em: sistemas de previsão, otimização de sistemas,

controle de processos, memórias associativas, agrupamento de dados (clusterização), reconhecimento e classificação de padrões, e aproximação universal de funções (VILELA; MATEUS, 2016, p. 7).

O uso de RNAs possui a vantagem de o usuário não ter a necessidade de conhecer a relação matemática entre as entradas e saídas da rede completamente, permitindo maior simplicidade (BUIRAGO; ASFOUR, 2017). No Quadro 1 é apresentada a comparação entre ambos os métodos geralmente utilizados em estatística e IC, sendo possível identificar a similaridade entre ambas as áreas em suas abordagens.

Quadro 1 - Comparação entre os modelos neurais e estatísticos.

REDES NEURAIS	ESTATÍSTICA
Entradas	Variáveis Exógenas
Saídas	Variáveis Endógenas
Pesos	Parâmetros
Conjunto de Treinamento	Amostra
Retropropagação	Aproximação Estocástica
Treinamento	Estimação

Fonte: VILELA; MATEUS (2016).


O interesse por redes neurais surgiu desde a época de filósofos como John Locke, George Berkeley e David Hume, do qual especulavam o relacionamento entre o espírito, a memória e os comportamentos do ser humano (LEITE, 1997, p. 19). Os estudos, no entanto, só passaram a ser mais bem desenvolvidos a partir dos avanços da neurociência, culminando no surgimento do neurônio artificial por McCulloch & Pitts (HAYKIN, 2001).

Os neurônios artificiais foram primeiramente definidos por McCulloch & Pitts em 1943, e logo em seguida transformado em algoritmo por Donald Hebb em 1949 (KOPILER et al, 2019, p. 28). McCulloch foi um psiquiatra e neuro anatomista, formado no Instituto tecnológico de Massachusetts, e passou 20 anos de sua vida estudando a representação de um fenômeno nervoso. Em 1942, Pitts, um matemático talentoso formado na Universidade de Illinois, se uniu a McCulloch na pesquisa, unificando neurofisiologia e lógica matemática (HAYKIN, 2001). Assim, foram criados os

neurônios artificiais, voltados para a realização de tarefas de cunho cognitivo e/ou criativo.


O neurônio artificial é tido como uma representação matemática do neurônio biológico, em termos de estrutura e funcionamento, de forma bem primitiva. Estes neurônios são “elementos de processamento divididos em camadas interconectadas que recebem estímulos e propagam até a camada de saída onde se obtém um novo estímulo” (PEREIRA et al, 2018). Na Figura 1 está contida uma representação da estrutura do neurônio artificial elaborada por McCulloch & Pitts, e na Figura 2 é mostrada a imagem de um neurônio biológico do qual se inspiraram ambos os criadores.

Figura 1 - Estrutura do Neurônio artificial.



Fonte: elaborada pelo autor.

Figura 2 - Conceito do neurônio artificial baseado no neurônio biológico.



Fonte: KOPILER et al (2019).


A partir do desenvolvimento do neurônio artificial, foram introduzidas as redes tipo Perceptron (criada por Rosenblatt) em 1959 (ROSENBLATT, 1958), definido um modelo computacional com a capacidade de classificar padrões linearmente separáveis por meio de um algoritmo de correção de erros. A rede Perceptron se utiliza do teorema da convergência, e é capaz de responder positivamente ou negativamente a um conjunto de sinais aplicados na sua entrada.

Em 1957, foi provado, por Kolmogorov, um importante teorema da teoria de funções que, mais tarde, foi utilizado para provar a capacidade de redes neurais em representar funções. Contudo, foi somente em 1960 que, a partir do trabalho de Widrow-Hoff (WIDROW, 1990), um algoritmo de ajuste dos parâmetros do Perceptron foi elaborado, tendo como base a regra delta (HAYKIN, 1994).

A partir do algoritmo criado por Widrow, foi possível elaborar a rede ADALINE (do inglês *Adaptive Linear Element*, ou elemento linear adaptativo), surgindo assim uma máquina capaz de classificar padrões lineares, de funcionamento bem semelhante à rede Perceptron, mas trabalhando de forma a minimizar o erro da saída pelo método dos mínimos quadrados, enquanto no Perceptron a adaptação ocorre até os padrões estarem separados. Posteriormente, graças a Rumelhart, surge o algoritmo de retropropagação (RUMELHART, 1986), possibilitando o cálculo dos parâmetros de uma rede neural e permitindo a sua aplicação em uma série de problemas de diversos campos da ciência, com maior enfoque na previsão de séries temporais (LEITE, 1997).

Nos neurônios descritos por McCulloch & Pitts, a inteligência se concentra nos pesos, já que o neurônio se baseia na soma ponderada das várias entradas. A Figura 3 representa a estrutura de uma RNA simples composta de um único neurônio, onde cada entrada passa por seu respectivo peso e então aplicada ao neurônio, para então originar o sinal de saída.

Figura 3 - Estrutura de uma RNA composta de um único neurônio artificial.




Fonte: adaptado de VILELA; MATEUS (2016).

O resultado da soma ponderada das entradas já multiplicadas pelos seus pesos é chamado de campo local induzido ou potencial de ativação do neurônio, que em seguida passa por uma função de ativação linear ou, na maioria dos casos, não linear, que originará a saída do neurônio. Nas funções de ativação não lineares, somente haverá saída se ocorrer o *threshold* de ativação, ou seja, se a soma dos seus estímulos exceder um nível pré-definido.

Na Figura 4 estão contidas as principais funções de ativação usadas em RNAs, onde as mais recorrentes são a logística e tangente hiperbólica, pois são diferenciáveis e tem comportamento mais gradual nas regiões de transição, permitindo maior nuance na resposta.

Figura 4 - Principais tipos de funções de ativação.



Fonte: elaborada pelo autor.

Dentre as arquiteturas, existem três classes mais distintas, segundo Haykin (2011): Perceptron (alimentada adiante de camada única e acíclicas, de capacidades extremamente limitadas), Perceptron de Múltiplas Camadas (ou MLP, do inglês *Multi-Layer Perceptron*) (ROSENBLATT, 1958) e Redes Recorrentes (possuem ao menos um laço de realimentação, para aprendizagem e desempenho, usando elementos de atraso unitário que representem um comportamento dinâmico não linear).

Existem diferentes tipos de algoritmos de treinamento para ajuste dos pesos sinápticos, de maneira a minimizar o erro na saída com relação ao desejado. Algoritmos de treinamento supervisionado, por exemplo, avaliam a discrepância entre a resposta desejada e a saída fornecida pela rede (no caso conhecido do *backpropagation*, ou retropropagação) (WIDROW, 1990), possuindo comportamento em duas fases: propagação das entradas pela rede e propagação do erro obtido em um sentido contrário.

Conforme KOPILER et al (2019):

A versão de uma única camada é chamada de rede de perceptrons e praticamente não é usada, posto que Minsky e Papert provaram no final da década de 60 que este tipo de rede só conseguia classificar corretamente problemas linearmente separáveis. Isto inclusive atrasou o desenvolvimento

da área até que Rummelhart, no início da década de 80, desenvolveu o algoritmo de Backpropagation para o treinamento de redes de múltiplas camadas, problema que, até então era considerado sem solução. (KOPILER et al, 2019, p. 29)

Em relação ao *backpropagation*, o erro da camada de saída é usado para corrigir o erro das camadas anteriores, através de retroação ou realimentação. Porém, sua principal limitação é a lentidão, pois procura não perder as variações do espaço de busca, e acontece devido ao problema dos gradientes explosivos e gradientes evanescentes, onde, para o primeiro caso, ocorre um grande aumento da norma do gradiente no ajuste dos pesos sinápticos durante a etapa de treinamento (no qual o gradiente é calculado utilizando a derivada), e para o segundo caso, ocorre o oposto, onde a norma do gradiente tende a ser nula, impossibilitando o aprendizado da correlação entre eventos temporais mais distantes envolvendo séries temporais (PASCANU, Razvan; MIKOLOV, Tomas; BENGIO, Yoshua, 2013).

Procurando uma alternativa de acelerar o treinamento via *backpropagation*, na década de 90, foram desenvolvidos algoritmos muito mais rápidos como Quickprop e RProp (para que o treinamento pudesse escapar do problema de mínimos locais), se popularizando na época e originando a MLP.

No horizonte de previsão a curto prazo, alguns métodos utilizados atualmente são a suavização exponencial de Holt-Winters, a análise da componente fundamental, ARIMA (*Auto Regressive Integrated Moving Average*, ou média móvel integrada autorregressiva) (O'DONOVAN, 1983), sistemas de inferência nebulosa (ou *fuzzy*), sistemas híbridos e RNAs. Porém, não existem muitos métodos para previsões de períodos mais curtos, sendo as existentes as já conhecidas, como estimadores Kalman, sistemas de inferência *fuzzy*, modelos autorregressivos, ARMA (do inglês *Autoregressive Moving Average*, média móvel autorregressiva) e RNAs. Na maioria das previsões de séries temporais, no entanto, utilizam-se RNAs com uma camada escondida e funções do tipo sigmoide como função de ativação nos nós ocultos, com o nó de saída utilizando uma função de ativação do tipo linear.

De forma geral, as RNAs vem sendo cada vez mais aplicadas em diversas atividades de previsão de séries temporais, tais como na previsão de séries temporais financeiras ou caóticas e de tráfego de rede de comunicação. Em especial, quando a série temporal é muito ruidosa e com a dinâmica do sistema de característica não linear, em muitos casos as RNAs superam as técnicas lineares já estabelecidas, como

por exemplo os modelos Box-Jenkins (O'DONOVAN, 1983). Nestes casos, a explicação para a melhor precisão na predição e melhor tolerância ao ruído está na inerente não linearidade dos modelos RNA (XIE, 2009). Por entenderem muito da dinâmica subjacente aos dados, elas realizam um bom trabalho de extrapolação e originam previsões relativamente confiáveis e precisas.


2.3 REDE NEURAL NARX

A rede a ser utilizada neste trabalho é o modelo NARX (do termo em inglês “*Nonlinear Autoregressive Exogenous*”, ou rede não linear autorregressiva de variáveis exógenas), tendo sido testada com sucesso em trabalhos na predição de chuvas, por exemplo, e em diversos outros trabalhos presentes na bibliografia atual mostrou resultados melhores se comparada com algoritmos lineares como máquinas vetoriais de suporte, usada para predição de tráfego, e obteve precisão de predição superior aos modelos RNN (*Recurrent Neural Network*, sendo redes neurais recorrentes) (SHENVI & VIRANI, 2023).

A rede NARX se trata de um modelo dinâmico que incorpora conexões de realimentação recorrentes da camada de saída para a camada de entrada com unidades de atraso temporal (LEONTARITIS, 1985a), tornando-a uma ferramenta mais eficiente para fins de modelagem e validação, por demonstrarem melhor generalização e convergência mais rápida do que outros modelos de redes neurais convencionais (SHENVI & VIRANI, 2023).

Conforme Kaminski (et al, 2021, p. 2), se tratando da arquitetura da rede ao ser comparada com demais RNAs, “outros modelos apresentam dinâmica apenas na camada de saída, enquanto, por possuir entradas externas, o modelo NARX apresenta dinâmica tanto na camada de saída como na camada de entrada”. Logo, as entradas e as saídas do estado atual têm influência no valor de saída do próximo estado (por ser uma rede do tipo recorrente), permitindo com que ela se torne muito mais dinâmica. Na Figura 5 é apresentada a estrutura geral desse tipo de rede com o laço de realimentação.

Figura 5 - Estrutura geral da arquitetura da rede NARX.



Fonte: BEZERRA et al (2011).

Utilizando-se de uma analogia a outra rede muito usada no trabalho com bancos de dados complexos e de grandes proporções, a rede NARX pode ser considerada como sendo uma rede MLP no qual a entrada consiste na própria saída realimentada e uma entrada exógena, ambas em atraso (CAMPOS, 2012, p. 4). Ou seja, as saídas estimadas são realimentadas à entrada da rede, fazendo com que possua uma estrutura única se levada em consideração a maneira como os laços de alimentação são organizados. Tal peculiaridade pode ser confirmada ainda pelo trabalho realizado por França et al (2019, p. 351), no qual, segundo ele, a rede NARX é tida como “[...] uma MLP com realimentação da sua saída para a entrada, com uma linha de atrasos idêntica à linha de atrasos da entrada”. Essa característica permite aumentar a sua capacidade de mapeamento não linear, com maior escopo de detecção de características comportamentais de conjuntos de dados mais desordenados.

De acordo com Alcântara (2020), pode-se caracterizar a rede NARX nos tipos MLP e Polinomial:

[...] possuem boa capacidade de resolver problemas de natureza não linear, o que as favorece na seleção de regressores que é realizada pela função estática da própria rede, possuindo maior capacidade de não linearidade se comparadas aos modelos NARX polinomiais. (ALCÂNTARA, 2020, p. 30 apud AGUIRRE, 2007)

A diferença entre os modelos NARX MLP e NARX Polinomial está principalmente na forma como a função não linear de ativação dos neurônios da camada escondida é representada, onde, no primeiro, ela representa as diversas camadas e funções de ativação, enquanto na segunda ela está relacionada a um polinômio de primeiro grau.

As redes NARX possuem uma ferramenta estatística chamada de validação cruzada, e a rede por si só representa matematicamente uma importante e útil classe de sistemas não lineares de tempo discreto (ANDRADE, 2014).

Considerando as entradas internas da rede u de enésimo valor m , representando um vetor de dados de entrada, e saídas y de enésimo valor anterior p , as entradas da rede $\underline{x}$ assumem a forma apresentada na Equação 1, já normalizadas.

$$\underline{x}(t) = [y(t-1), y(t-2), \dots, y(t-p), u(t-1), u(t-2), \dots, u(t-m)] \quad (1)$$

Para a aproximação da função original do sistema a uma equivalente, adotada pela própria rede, utiliza-se, conforme a Equação 2, de uma função de entrada $f(\underline{x}(t))$, para transformação das entradas, somada aos respectivos pesos ponderados da rede w .

$$y(t) = f(\underline{x}(t)) + w(t) \quad (2)$$

Para uma rede neural $\hat{y}$ que se aproxime da função original f , utiliza-se a função de parametrização $\emptyset$, definida em Leite (1997), como pode ser observado na Equação 3.

$$\hat{y}(t) = f(\emptyset(t), \underline{x}(t)) \quad (3)$$

A função de transferência (que caracteriza a alteração da entrada para obtenção de uma resposta de saída) é tida de acordo com a Equação 4, onde as entradas u (quantidade k) internas da rede assumem como valores a soma dos produtos das entradas x (de comprimento j) com seus respectivos pesos (mesma quantia das entradas internas, referentes aos neurônios da primeira camada).

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (4)$$

O modelo de espaço de estados está representado na Equação 5, resultando como saída da rede descrita pela Equação 6, considerando uma função g que varia conforme a função de espaço de estados s e as entradas internas u e os pesos ponderados w , e considerando um erro e .

$$s(t + 1) = f(s(t), u(t), w(t)) \quad (5)$$

$$\hat{y}(t) = g(s(t), u(t)) + e(t) \quad (6)$$

O peso bias (para ativação do neurônio, b) se trata de um valor de limiar, e a sua contribuição define a função de saída, dado pela Equação 7, onde ele representa uma contribuição para a k -ésima saída da rede.

$$y_k = \Phi(u_k + b_k) \quad (7)$$


Com base nas informações contidas nas equações anteriores, a rede se formula conforme a Equação 8, e o seu resultado de acordo com a Equação 9, onde a saída prevista está em função das entradas x da rede e das entradas $\bar{u}$ e saídas $\bar{y}$ internas em atraso, tidas em amostras n , com entradas x atrasadas em $d_E - 1$ amostras e entradas internas $\hat{x}$ atrasadas em $d_Y - 1$ amostras, com d_E e d_Y sendo respectivamente a quantidade total de entradas amostrais e entradas internas da rede.

$$y(n) = f[x(n); \bar{u}(n); \bar{y}(n - 1)] \quad (8)$$

$$y(n) = f[x(n), \dots, x(n - d_E + 1); \hat{x}(n), \dots, \hat{x}(n - d_Y + 1)] \quad (9)$$

Na Figura 6 está representada a rede NARX com base em sua estrutura geral com enfoque nas entradas da rede, evidenciando que as próprias saídas em outros instantes de tempo anteriores são tidas como variável de entrada.


Figura 6 - Estrutura da rede NARX com enfoque nas entradas e saídas.



Fonte: adaptado de LEITE (1997).

Mesmo sendo uma rede com feedback (em malha fechada), pode ser representada em malha aberta se for considerada a saída do estado anterior $y(n-1)$, disponível durante o treinamento, como uma nova entrada no lugar do laço de realimentação. Assim, ela se apresenta como uma rede de alimentação direta com treinamento via *backpropagation*, melhorando a eficiência e a precisão no ajuste dos pesos (a rede se baseia no estado de saída anterior, sem erro). Depois ela é utilizada como uma rede em malha fechada. Desta forma, cada saída fornecida pela própria rede exerce influência sobre a resposta no próximo valor, como pode ser observado na Figura 7.

Figura 7 - Rede NARX em malhas aberta e fechada.



Fonte: adaptado de KAMINSKI (2021). (a) Rede em malha fechada e (b) rede em malha aberta.

Conforme descrito por Kaminski (2021), o treinamento via *backpropagation* utilizado pela rede NARX possui como otimizador o algoritmo de Levenberg-Marquadt, no qual:

O algoritmo de Levenberg-Marquadt (LM) é uma variação do método de Newton, designado a minimizar a soma dos quadrados de outras funções não-lineares, sendo adequado para o treinamento de redes neurais em que a avaliação de desempenho é feita utilizando o erro quadrático médio (EQM). (KAMINSKI et al, 2021 apud HAGAN, 2016)

O algoritmo se divide em três partes:

- I. **Treinamento:** uma parte do conjunto de dados é utilizada para o treinamento da rede de fato, realizando o ajuste dos pesos sinápticos;
- II. **Validação:** ocorre a validação dos dados, onde outra parte do conjunto é tida como critério de parada, no intuito de melhorar a eficiência e otimizar o tempo de treinamento da rede (isto é, este conjunto de dados é testado na rede neural e, quando o erro passa a aumentar, o treinamento é interrompido);
- III. **Teste:** um último conjunto é destinado ao teste da rede neural já treinada, estimando sua precisão e simulando o comportamento para dados externos excluídos da fase de treinamento.


A rede é inicialmente treinada em malha aberta (ou série-paralela, onde o alvo e os dados de entrada são introduzidos na arquitetura), equivalente a uma rede *feedforward*, na qual os valores reais são utilizados como entrada ao invés de realimentar os valores estimados, tornando o processo muito mais consistente e preciso. Em seguida, ela se utiliza dos valores atuais da carga para a realização da previsão, provendo valores futuros que serão posteriormente reutilizados para recalcular os pesos, realizando um ajuste mais preciso com relação aos dados originais. Depois de ajustados os pesos dos nós, é feito o cálculo da saída e realimentada à entrada, tornando-se uma rede *feedback* (recorrente, trabalhando em malha fechada).

Durante a etapa inicial de treinamento, a saída atual fica disponível, e é realimentada à rede para a determinação dos pesos e do critério de parada, porém, durante as etapas posteriores de previsão durante o treinamento, os valores reais de saída não mais estarão disponíveis após a primeira atualização dos pesos, sendo

então utilizadas para os novos processos de ajuste (épocas) as saídas previstas pela própria rede. A saída prevista em atraso é usada para gerar as próximas previsões até alcançar a estabilidade pelo critério de parada (desta vez alterando o alvo pelos valores de saída calculados).

Na Figura 8 é demonstrado um modelo equivalente da rede NARX estruturada como uma rede MLP com realimentação das saídas nas entradas.

Figura 8 - Rede NARX estruturada do ponto de vista de uma MLP.



Fonte: adaptado de XIE (2009). (a) Rede NARX como MLP com realimentação e (b) sem realimentação.

Quanto à construção da rede, ela se inicia com a estrutura de uma rede Perceptron *feedforward*, para compreender o comportamento da saída em um certo instante de tempo, e com a utilização dos valores das entradas, modelado pela função não linear pelo modelo regressivo da camada de saída, como apresentado na Equação 10.

$$y_t = \Phi[\beta_0 + \sum_{i=1}^q \beta_i h_{it}] \quad (10)$$

Sendo:

Φ : função de ativação linear das saídas;

β : pesos da camada de saída;

q : quantidade de neurônios da camada de saída;

h : saída da camada escondida.

A camada escondida h , da Equação 11, é tida por meio de uma função não linear Ψ que depende da função de ativação relacionada aos pesos Υ da camada de

entrada (neste caso, a função de ativação é do tipo sigmoide 1, como descrita na Equação 12), com a camada de entrada contendo n neurônios.

$$h_{it} = \Psi[Y_{i0} + \sum_{j=1}^n Y_{ij}x_{jt}] \quad (11)$$

$$\Psi(t) = \frac{1}{1 + e^{-t}} \quad (12)$$

A junção das Equações 10 e 11 produzem a saída apresentada pela Equação 13, e a camada escondida na Equação 14, onde δ_{ir} são os pesos do termo de realimentação $h_{r,t-1}$ em atraso (r , neste caso, pode ser definido como a época em que se situa a etapa de treinamento) (NEVES, 2016).

$$y_t = \Phi\{\beta_0 + \sum_{i=1}^q \beta_i \Psi[Y_{i0} + \sum_{j=1}^n Y_{ij}x_{jt}]\} \quad (13)$$

$$h_{it} = \Psi[Y_{i0} + \sum_{j=1}^n Y_{ij}x_{jt} + \sum_{r=1}^q \delta_{ir}h_{r,t-1}] \quad (14)$$

Portanto, a saída em sua forma completa se torna como apresentada na Equação 15, e para diversas camadas de saída (de k saídas) conforme a Equação 16, contendo N camadas intermediárias.

$$y_t = \Phi\{\beta_0 + \sum_{i=1}^q \beta_i \Psi[Y_{i0} + \sum_{j=1}^n Y_{ij}x_{jt} + \sum_{r=1}^q \delta_{ir}h_{r,t-1}]\} \quad (15)$$

$$y_t^k = \Phi\{\beta_0^k + \sum_{l=1}^N \sum_{i=1}^q \beta_i^l \Psi[Y_{i0}^l + \sum_{j=1}^n Y_{ij}^l x_{jt} + \sum_{r=1}^q \delta_{ir}h_{r,t-1}]\} \quad (16)$$

Através da função de Erro Quadrático Médio (EQM ou MSE, do inglês “*Mean Square Error*”), verifica-se o desempenho pelo erro médio quadrático entre os valores desejados (alvos) e a saída da previsão, uma vez que, por meio da diferença do quadrado dos erros medidos pelo quadrado dos erros estimados, é possível

determinar o desempenho da rede. Um baixo erro indica um bom desempenho da RNA e um alto erro aponta falhas e insuficiências em seu funcionamento, como apresentado na Equação 17, onde e_i representa o erro percentual do resultado da predição com relação à entrada atual.

$$MSE = \frac{1}{n} \sum_{i=1}^n (e_i)^2 \quad (17)$$

O MAPE (erro percentual absoluto médio, do inglês “*Mean Absolute Percentage Error*”) calculado pela Equação 18, sendo y o valor previsto de saída e x o valor original ou esperado do resultado da rede.

$$MAPE(\%) = \frac{1}{n} \left| \sum_{i=1}^n \frac{y_i - x_i}{x_i} \right| * 100 \quad (18)$$

A correlação, por sua vez, é dada pela Equação 19.

$$r = \frac{\sum_{i=1}^n (y_i - \bar{y}_i) * (x_i - \bar{x}_i)}{\sqrt{\sum_{i=1}^n (y_i - \bar{y}_i)^2 * \sum_{i=1}^n (x_i - \bar{x}_i)^2}} * 100 \quad (19)$$

Para a avaliação do desempenho da rede, são utilizados como métricas de erro:

- MAE (erro médio absoluto): realiza a média dos erros absolutos de cada saída prevista (y_i) com relação ao valor alvo (t_i), de acordo com a Equação 20;

$$MAE = \frac{1}{N} \sum_{i=1}^N |t_i - y_i| \quad (20)$$

- MSE: usado como medida de desempenho durante a fase de treinamento, sendo melhor quanto mais próximo de 0, de acordo com a Equação 21;

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (21)$$

- SAE (erro absoluto da soma): calcula o somatório dos erros absolutos, de acordo com a Equação 22;

$$SAE = \sum_{i=1}^N |t_i - y_i| \quad (22)$$

- SSE (erro quadrático da soma): calcula a soma de todos os erros quadráticos, de acordo com a Equação 23;

$$SSE = \sum_{i=1}^N (t_i - y_i)^2 \quad (23)$$

- CROSSENTROPY (entropia cruzada): usada principalmente para classificação, de acordo com a Equação 24 para saídas variando entre 0 e 1 e com a Equação 25 para saídas binárias ou multiclass;

$$CROSSENTROPY = -\frac{1}{N} \sum_{i=1}^N [t_i * \log(y_i) + (1 - t_i) * \log(1 - y_i)] \quad (24)$$

$$CROSSENTROPY = \frac{1}{N} \sum_{i=1}^N (-t_i * \log(y_i)) \quad (25)$$

- MSEPARSE (erro quadrático médio com peso L2 e reguladores de esparsidade): de acordo com a Equação 26, no qual α é o coeficiente de regularização dos pesos w_j^2 e β o termo de esparsidade.

$$MSE_{SPARSE} = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 + \alpha * \sum_j w_j^2 + \beta * esparsidade \quad (26)$$

Outros fatores que influenciam na estrutura da rede são:

- Tamanho da entrada;
- Normalização dos dados (de acordo com a Equação 27);

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (27)$$


- Tamanho da amostra para treinamento e teste;
- Medidas de performance.

Em redes NARX, há um número limitado de arquiteturas de realimentação (*feedback*) que partem do neurônio de saída ao invés dos neurônios ocultos da camada escondida. Comparada a outras RNAs, ela não apresenta nenhuma perda computacional e são pelo menos equivalentes às máquinas de Turing em relação ao seu processo de aprendizado.

Conforme um exemplo apontado por XIE (2009, p. 1275), “[...] tem sido reportado que aprendizado em gradientes-descendentes pode ser mais eficaz em redes NARX do que em outras arquiteturas recorrentes com ‘estados ocultos’”. Porém, mesmo com tais vantagens, é uma rede que ainda não foi bem explorada, devido ao problema de seleção da ordem de memória, uma vez que é análogo a escolher um subconjunto ótimo de variáveis regressivas na construção de modelos estatísticos (XIE, 2009), onde se deseja a menor variância nas previsões.

A Figura 9 representa a rede completa com a descrição detalhada de seu funcionamento, de forma resumida.

Figura 9 - Descrição detalhada do funcionamento e estrutura da rede NARX.



Fonte: ALCÂNTARA (2020).

No uso de RNAs para previsão, são considerados dois tipos de entradas: o alvo, representando o resultado ou saída desejada, e as entradas de dados em si,

compreendendo o conjunto de amostras que servirão de base para a rede realizar a previsão. Desta maneira, uma vantagem presente na estrutura série-paralela da NARX é que a rede resultante possui uma arquitetura puramente *feedforward*, e o modo de realimentação pode ser utilizado para treinamento.

Em condições gerais, o estado determinístico de um sistema dinâmico pode ser fielmente reconstruído com o uso de uma janela de tempo finito ao longo de uma série temporal observada, no qual a janela temporal, ao conter uma coleção de valores defasados em um espaço vetorial dimensional fiéis à série temporal original, pode prover informações suficientes para reconstruir os estados de um sistema dinâmico observável (XIE, 2009, p. 1276).

Quanto às aplicações da rede NARX, é utilizada principalmente para sistemas dinâmicos que não apresentam linearidade, com alguns campos em potencial para seu uso na caracterização de tráfego de redes de comunicação e na previsão de séries temporais caóticas (VILELA; MATEUS, 2016, p. 10).


3 OBJETIVOS

O presente trabalho tem como principal objetivo investigar o desempenho da rede NARX na previsão de carga elétrica a curto prazo. Foram utilizados dados históricos de demanda de carga elétrica, fornecidos pela Empresa de Energia Elétrica *LIGHT* do Rio de Janeiro e, estes foram utilizados no processo de treinamento da rede neural e validação dos resultados das previsões. Com este sistema espera-se obter respostas de demandas que condizem com os valores reais de carga para limites de erro conforme adotados pelo sistema elétrico.

4 MATERIAL E MÉTODOS

Para o processamento da rede NARX, foi utilizada a *Toolbox* de redes neurais do MatLab 2022b e, foi realizada devidas alterações na matriz de dados de entrada na rede. Utilizou-se dados históricos de cargas elétricas horárias do ano de 1998 considerando os feriados nacionais. Na Figura 10 é apresentado o modelo em diagrama de blocos disponibilizado pelo Matlab da rede NARX utilizada a partir da *Toolbox*.

Figura 10 - Diagrama de blocos da estrutura da rede NARX.



Fonte: elaborada pela Toolbox do Matlab.

Foram fornecidos dados históricos de carga da empresa distribuidora de energia elétrica LIGHT, do Rio de Janeiro/RJ. Os dados disponíveis foram referentes aos anos de 1996, 1997 e 1998, onde se trabalhou com o ano de 1998 para a previsão de um único dia (por ser o ano mais recente disponibilizado pela empresa). Para a análise, reorganizou-se a planilha contendo as informações das demandas diárias ao longo do ano, divididas em horas (1h a 24h), separando cada período em meses. Os dados originais foram divididos como mostrado na Figura 11.

Figura 11 - Organização original dos dados.

	A	B	C
1	Data	Hora	KW
2	01/01/1998	1	3291.7
3	01/01/1998	2	3297.3
4	01/01/1998	3	3324.8
5	01/01/1998	4	3330.4
6	01/01/1998	5	3284
7	01/01/1998	6	3203.6
8	01/01/1998	7	3016.7
9	01/01/1998	8	2912.2
10	01/01/1998	9	2842
11	01/01/1998	10	2822.4
12	01/01/1998	11	2739.7
13	01/01/1998	12	2635.8
14	01/01/1998	13	2594.8
15	01/01/1998	14	2585.2
16	01/01/1998	15	2609.9
17	01/01/1998	16	2622
18	01/01/1998	17	2634.4
19	01/01/1998	18	2625
20	01/01/1998	19	2624.5
21	01/01/1998	20	2816.6
22	01/01/1998	21	3326.4
23	01/01/1998	22	3492.9
24	01/01/1998	23	3713.1
25	01/01/1998	24	3736.8


Fonte: elaborada pelo autor.

Como pode ser observado, as cargas foram separadas por linhas, com as correspondentes informações de data, hora do dia e valor registrado de consumo em kilowatts. Os dados foram separados de forma mensal para a realização do estudo da rede, reorganizando-os em uma matriz de dia por hora, onde cada linha representa o dia do mês e cada coluna representa a hora do registro, com o conteúdo sendo os valores das cargas.

A separação dos dados em matriz foi necessária para a sua inserção na entrada da rede NARX pela estrutura disponibilizada pela *Toolbox* de redes neurais do Matlab. Contudo, dependendo de como é feita a escolha do tempo de *delay* (tempo de atraso do treinamento), alguns dados das horas iniciais do dia são utilizados como valores iniciais e não são contabilizados na previsão para a resposta de saída da rede, eliminando o registro inicial (por exemplo, se realizada a previsão de um dia contendo 24 horas na entrada, com tempo de *delay* de dois segundos, a resposta de saída prevista terá 22 horas, com previsões das 3h às 24h).

Nas Figura 12 é apresentada a visualização gráfica disponibilizada pela toolbox de redes neurais do MatLab para predição contendo informações a respeito de dados como: alvo de treinamento (para cálculo do erro e determinação do critério de parada), saída prevista após o treinamento, alvos de validação, saídas de validação, alvos de teste e saídas de teste, juntamente com as respostas de erro e saída da rede definitiva (após a finalização de todas as etapas de treinamento, validação e teste).


Figura 12 - Visualização gráfica dos resultados apresentados pela toolbox.



Fonte: elaborada pela Toolbox do Matlab.

Para a realização do código em si, foi utilizado o comando `nnstart`, que abre a aba de redes neurais e possui as opções de ajuste (`nftool`), reconhecimento de padrões (`nprtool`), agrupamento (`nctool`) e série temporal (`ntstool`), sendo a última a usada para previsões de séries de dados temporais, como pode ser visualizado na Figura 13.


Figura 13 - Interface interativa de abertura da toolbox do Matlab.



Fonte: elaborada pela Toolbox do Matlab.

Na Figura 14 são apresentadas as redes neurais disponíveis para realizar diferentes tipos de previsões de séries temporais, dentre elas a NARX (pode prever resultados em redes NAR ou não lineares de entrada-saída).

Figura 14 - Seleção do tipo de rede neural a ser utilizada para análise dos dados.




Fonte: elaborada pela Toolbox do Matlab.

Para os dados de entrada, é necessário maior atenção e cuidado antes de serem fornecidos diretamente na toolbox. Podem ser escolhidos para as entradas um

vetor de células ou uma matriz, como ilustrado na Figura 15, com a ordem temporal dos dados disposta em linhas.

Figura 15 - Seleção dos dados de entrada da rede neural.




Fonte: elaborada pela Toolbox do Matlab.

Para o treinamento da rede, devem ser escolhidos o quanto do conjunto de dados será usado para as etapas de validação e teste de dados, em percentual, onde o treinamento é dado pela subtração da quantidade total de dados e da validação e teste (treinamento = 100% - validação% - teste%), bem como a escolha da quantidade de células da camada escondida (passa por uma função não linear), que será utilizada como entrada para a camada de saída (função linear).

Para efeitos de teste, foi utilizado para a predição 5% dos dados para validação e teste e 90% dos dados para treinamento, com tamanho de camada intermediária de 10 neurônios e tempo de atraso (delay) de 2 segundos, bem como método de cálculo do erro MSE para validação dos resultados e treinamento via Levenberg-Marquardt (Backpropagation), sendo estes dados os disponibilizados pela toolbox como configuração inicial para a rede. Na Figura 16 é ilustrada a estrutura da rede e a escolha realizada dos parâmetros.


Figura 16 - Estrutura disponibilizada pelo toolbox da rede construída.



Fonte: elaborada pela Toolbox do Matlab.

Depois de determinada a estrutura da rede, são realizados o treinamento e o teste, para a obtenção da resposta de saída. Na Figura 17 são mostrados os resultados fornecidos pela toolbox após o treinamento para uma predição inicial do dia 1 de abril usando como entrada de dados o mês de março.

Figura 17 - Funcionamento da etapa de treinamento da rede pela toolbox.




Fonte: elaborada pela Toolbox do Matlab.

Assim como pode ser visto pela figura, no treinamento, a rede NARX fornece diferentes informações que podem ser levadas em consideração para diferentes resultados. Finalizado o treinamento, podem ser consultadas várias plotagens de gráficos para diferentes aspectos relacionados aos parâmetros escolhidos, sendo eles estado do treinamento, métricas de erro, histograma de erro, resposta temporal, autocorrelação de erro e correlação de erro de entrada. Para a pesquisa, utilizou-se apenas dos resultados de saída e da análise dos erros e MAPE, a fim de verificar o desempenho da rede. Além disso, é possível realizar testes para outros conjuntos de dados que podem ser inseridos na entrada depois do treinamento.

Outras opções fornecidas pela toolbox são a exportação das plotagens gráficas, da estrutura da rede e geração do código em formato “.m” (formato Matlab, disponível nas versões simplificada e comentada detalhadamente), o que possibilita adaptações diretamente no código para diferentes aplicações ou análises. Na Figura 18 são apresentadas estas diferentes opções.

Figura 18 - Opções de gráficos disponibilizados sobre a rede NARX.



Fonte: elaborada pela Toolbox do Matlab.

Na previsão, por se tratar de uma rede neural de treinamento supervisionado na primeira etapa de ajuste dos pesos, são utilizados os valores originais da carga diária, sendo necessário um tratamento prévio dos dados (como calcular a média de cargas para este dia específico de todos os anos anteriores, que não apresentem anomalias). Para cada novo treinamento são obtidas diferentes respostas visto a alteração dos pesos durante o processo, conforme o mecanismo de adaptação da própria rede NARX (com ajuste inicial dos pesos feito aleatoriamente).

Pela toolbox, a alteração do tipo de treinamento e do método de cálculo do erro não são possíveis, sendo necessário realizar alterações diretas no código detalhado fornecido pelo comando “*Generate Code*”. Para a elaboração do código correspondente à rede neural, realizaram-se as devidas adaptações para organização e filtragem dos dados, definição das configurações da rede e obtenção dos resultados, juntamente à adição de um processo iterativo de readaptação em malha fechada para

diminuição do erro máximo, estabelecendo limites de 2,5% e 5% com relação aos valores originais das cargas horárias para o dia a ser previsto. Em malha aberta, cada época (novo reajuste dos pesos utilizando as saídas internas previstas antes da convergência) permite um ajuste mais preciso dos pesos, porém, se feita uma nova simulação, os pesos são reiniciados pela divisão randômica dos dados de entrada para treinamento, validação e teste, obtendo resultados completamente diferentes, sendo necessário o uso de iterações sucessivas no treinamento para não haver a perda dos ajustes de pesos durante o treinamento inicial em malha fechada.


Antes de entender sobre a estrutura da rede e seu funcionamento, considerou-se inicialmente a criação de um filtro de dados em prol de obter uma melhor compreensão da relação entre as entradas (amostras diárias e dia a ser previsto) e a saída (previsão), através da alteração do período amostral para diferentes quantidades de meses subsequentes.

Para facilitar a análise, foram considerados como outras variáveis relevantes o dia da semana (numerados de 1 a 7, correspondendo de domingo a sábado) e a estação do ano (verão, outono, inverno e primavera, de numerações respectivas de 1 a 4). Estas variáveis foram levadas em conta pelo fato de que o perfil de cargas se altera conforme o dia da semana e estação do ano.

Como o país possui grande parte de sua matriz energética voltada às hidrelétricas, que são dependentes da quantidade de chuvas para geração (volume de água nos reservatórios, variando ao longo das estações do ano), há um impacto direto no preço de energia elétrica no decorrer do ano (conforme as bandeiras para alteração da tarifa de energia), estimulando a redução do consumo em meses de maior escassez de chuvas. A curva de demanda, por sua vez, se altera ao longo de cada dia da semana, especialmente em dias de fim de semana (sábados e domingos), onde o consumo tende a ser mais divergente com relação aos demais dias de semana de segunda-feira a sexta-feira.


Nas Figuras 19 e 20 são apresentados os fluxogramas do código utilizado para a elaboração do filtro de dados e da rede neural NARX, no qual na Figura 20 é apresentado o procedimento utilizado para as iterações durante o treinamento.

Figura 19 - Fluxograma do filtro de dados de entrada da rede NARX (parte 1).



Fonte: elaborada pelo autor.

Figura 20 - Fluxograma do filtro de dados de entrada da rede NARX (parte 2).



Fonte: elaborada pelo autor.

Como etapas de investigação para as previsões, foram adotados os seguintes procedimentos com as suas respectivas considerações:

- 1º: previsão do dia 1 dos meses de fevereiro, março e abril usando o mês anterior como entrada de amostras;
- 2º: previsão de 1 de abril usando o primeiro trimestre de 1998 como entrada de amostras;
- 3º: previsões para 14 de outubro considerando a correção do banco de dados;
- 4º: previsões para 14 de outubro com diferentes métodos de cálculo de erro;
- 5º: previsões para o Natal em mais de um dia com amostras de um a três meses;
- 6º: previsões para Tiradentes usando a mesma análise da quinta etapa para taxas de treinamento diferentes;
- 7º: previsões para o Dia de N. S. Aparecida de um a três dias com taxa de treinamento e período amostral fixos.

Na primeira, segunda e terceira etapas, foi feita a duplicação das duas primeiras colunas da matriz de cargas e do vetor alvo (1h e 2h repetidas), para obter a curva de demanda diária prevista para todo o período do dia, e depois sendo feita a convolução com o uso das duas últimas horas do dia anterior (23h e 24h) da terceira etapa em diante, a fim de obter melhor continuidade dos dados para a curva de demanda e verificar a melhoria nos resultados de saída da rede.


Para a previsão do primeiro dia de fevereiro, utilizou-se os dados de carga do mês de janeiro como entradas de amostra, e os dados de carga reais do primeiro dia de fevereiro como alvo para cálculo do erro. Depois de feitos os estudos iniciais para as predições dos primeiros dias de cada mês de fevereiro, março e abril, aumentou-se o escopo da pesquisa com uma predição do primeiro dia de abril utilizando o primeiro trimestre como entradas de amostra (meses de janeiro, fevereiro e março), para verificar o quanto alterariam os resultados para a previsão e seu comportamento frente ao aumento do banco de dados amostral, analisando a influência da sazonalidade da carga.

Até a terceira etapa utilizaram-se 10 neurônios na camada escondida, sendo uma configuração inicial da toolbox. Para as demais etapas, considerou-se 24, 48 e 72 neurônios da camada escondida para previsões respectivas de um dia, dois dias e três dias, para não haver a perda de dados durante a etapa de treinamento.

5 RESULTADOS E DISCUSSÕES

O primeiro passo foi realizar uma previsão com base no primeiro mês de janeiro, estimando a carga para o primeiro dia de fevereiro, e repetido o mesmo procedimento para os meses de fevereiro e março, com os resultados apresentados respectivamente conforme as Figuras 21, 22 e 23 de cada mês.

Figura 21 - Previsão para o dia 1 de fevereiro utilizando o mês de janeiro.



Fonte: elaborada pelo autor.

No caso da predição para o dia primeiro de fevereiro (domingo em pleno verão), o maior erro ocorrido foi às 3h no valor de 4,70%, e verifica-se que os erros se distribuem de forma não uniforme durante as primeiras horas do dia e, entre as 10h e 20h, ocorre uma variação entre 1% e 2%, com exceção das 20h, com 2,75% de erro. Este comportamento pode ser explicado pelo fato de que, durante este período inicial, a rede procura identificar o padrão da curva de carga (seja de aumento ou declínio), tendo como consequência maiores erros. Para o período entre as 10h e 20h, há uma alteração abrupta de demanda, com um rápido aumento das 10h às 11h e apresentando um perfil aproximadamente linear até as 17h, sendo de característica mais estável nesta hora e tendo um rápido crescimento das 20h até as 23h, alcançando o pico de demanda, e então sofrendo um decaimento na última hora do dia.


Figura 22 - Previsão para o dia 1 de março utilizando o mês de fevereiro.



Fonte: elaborada pelo autor.

Para o dia 1 de março (domingo de verão), a rede conseguiu realizar uma previsão extremamente precisa com o uso do mês de fevereiro como subconjunto amostral, com erro máximo de 7,30% às 22h, e com um erro mais expressivo às 18h, de 2,51%. Por se tratar de dias de domingo de início de mês na mesma estação do ano, foi possível obter uma melhor identificação da característica do perfil comportamental da curva de carga, e o erro mais expressivo das 22h é devido principalmente à alteração da curva de demanda a partir das 20h.

Figura 23 - Previsão para o dia 1 de abril utilizando o mês de março.




Fonte: elaborada pelo autor.

Para o dia 1 de abril (quarta de outono), há maior discrepância apenas no período inicial do dia, entre as 1h e 4h, em parte por utilizar as duas primeiras horas do dia duplicadas como entrada na rede, uma vez que pode entrar em choque com algum padrão comportamental da demanda em dias anteriores do banco de amostras (março), e em parte pelo próprio perfil da carga para os dias utilizados como amostras do mês anterior. A explicação para esse comportamento está no fato de que o mês escolhido pode ter apresentado diferenças significativas entre as semanas para os valores diários de potência, seja na demanda média diária ou no formato da curva de carga, correspondendo a um mês com maior quantidade de comportamentos (ou seja, menor sazonalidade da carga) e dificultando no trabalho da rede na identificação de um padrão.

Na Figura 24 são apresentados os resultados para a predição do dia 1 de abril com o uso do primeiro trimestre como entrada, na segunda etapa de investigação, onde observa-se que há uma mudança de comportamento da curva ao aumentar a quantidade de subconjuntos de amostras (dias) para a previsão, possuindo mais pontos com erros mais acentuados às 1h e 18h, sendo mais expressivo às 1h, com um erro de 3,73%.

Figura 24 - Predição para o dia 1 de abril utilizando o primeiro trimestre de 1998.



Fonte: elaborada pelo autor.

Pela figura, o resultado apresentado pode trazer indícios de que um aumento do conjunto de dados não necessariamente contribui com um menor erro nas previsões, já que, por apresentar menor sazonalidade, há a presença de dias que englobam diferentes curvas de demanda (mesmo se considerados os dias da semana, como apenas as segundas-feiras, por exemplo) cada qual com suas próprias características. A consequência é uma maior quantidade de perfis a serem considerados pela rede, não necessariamente possuindo um padrão, sendo mais notório ao considerar que o final do mês de março e início do mês de abril marcam um período de transição entre as estações de verão e outono.


Embora a falta de sazonalidade tenha influenciado as previsões para o dia 1 de abril utilizando o primeiro trimestre como amostras, a rede NARX ainda consegue ter um bom discernimento entre as especificidades de cada dia. Mesmo com dias que podem impedir uma melhor precisão nos resultados, como é possível verificar do período das 4h em diante, com exceção das 18h (erro de 1,64%, que é resultante da influência de algum dia em que a diferença de carga é muito maior do que o restante do período), a curva de demanda prevista apresentou um bom comportamento com relação à carga original.

Conforme já considerado com os resultados para a carga do dia 1 de abril, a sazonalidade da carga possui grande influência sobre as previsões, já que oferece de

forma direta uma maior quantidade de informações acerca do comportamento da demanda para conjuntos de dados diferentes, possuindo consequência principalmente no ajuste inicial dos pesos dos neurônios da camada escondida, bem como na etapa de cálculo para reajuste após a verificação (etapa de validação), não necessariamente melhorando a precisão das previsões.


Na terceira etapa de investigação, analisou-se o dia 14 de outubro, sendo uma quarta-feira depois de um domingo de feriado (12 de outubro, dia de Nossa Senhora Aparecida), com o uso do mês de setembro (e os 13 primeiros dias subsequentes de outubro) como período amostral, para verificar se a alteração das primeiras duas horas utilizadas como variáveis iniciais (de 1h e 2h de 14 de outubro para 23h e 24h do dia 13 de outubro, usando o mesmo método de convolução para o banco de dados) possibilitaria uma melhor predição para as primeiras horas. Além desta correção, identificou-se, no banco de dados, a presença de um curto-circuito para o dia 11 de outubro às 1h, tendo sido necessário substituí-lo pela média das potências dos dias de domingo do período amostral selecionado. O resultado previsto antes das correções está demonstrado na Figura 25, e o resultado após as correções na Figura 26.

Figura 25 - Resultado das predições para o dia 14 de outubro antes da correção.



Fonte: elaborada pelo autor.

Figura 26 - Resultado das previsões para o dia 14 de outubro após a correção.
Previsão corrigida para 14 de outubro com 1 mês de amostra



Fonte: elaborada pelo autor.

Comparando os resultados, é notório que as primeiras horas do dia (entre 1h e 5h) com o uso da convolução temporal em 2h (23h e 24h do dia anterior) aumentam a precisão da previsão, visto a melhora na continuidade dos dados para a curva de carga, auxiliando na identificação do seu padrão comportamental para este período inicial. Para ambos os casos, respectivamente, os erros máximos foram de 3,98% (3h) e 5,42% (24h), onde, por mais que o erro máximo tenha aumentado, ainda assim, o desempenho frente às demais horas é relativamente melhor se comparado às demais horas do dia (menor quantidade de pontos com erros expressivos nas primeiras horas do dia), com MAPEs de 0,46% e 0,29%.

Depois de verificado o comportamento da rede para um mês através do treinamento por EQM, a quarta etapa de investigação foi na análise do comportamento das previsões para diferentes métodos de cálculo do erro durante o treinamento, sendo eles:

- MAE (erro médio absoluto);
- MSE (erro quadrático médio, utilizado até então);
- SAE (erro absoluto da soma);
- SSE (erro quadrático da soma);
- CROSSENTROPY (entropia cruzada);

- MESPARE (erro quadrático médio com peso L2 e reguladores de esparsidade).

Os dados obtidos das previsões utilizando os diferentes métodos foram coletados para 50 iterações do treinamento, objetivando obter um perfil comportamental da rede no processo de adaptação para diferentes funções de métricas de erro, com os resultados apresentados conforme a Tabela 1.

Tabela 1 - Resultados para a alteração de métodos de cálculo de erro.

Método de cálculo de erro	MAPE (%)	Erro mínimo (%)	hora Emin (h)	Erro máximo (%)	hora de Emax (h)	Iterações
MSE	0,00016	$1,7182810^{-08}$	5	0,0033	14	17
MAE	0,00021	0	22	0,0049	10	7
SAE	0,01345	0	24	0,2171	11	3
SSE	0,04974	0	24	1,1860	19	14
CROSSENTROPY	0,05440	0	23	0,8165	5	3
MESPARE	0,05676	0	11	1,3607	22	7

Fonte: elaborada pelo autor.


De acordo com os resultados obtidos, o MSE foi o método que apresentou menor erro se considerado apenas o valor do MAPE e menor erro máximo, porém, sendo necessário um maior número de iterações do que os demais métodos. No caso de redes mais simples como a estudada, onde a necessidade por previsões mais precisas é maior, tanto o MSE quanto o MAE são ótimas alternativas (embora o MAPE do MAE seja menor do que usando o MSE, consegue atender à condição de erro máximo menor do que 5% com um menor número de iterações, sendo mais rápido). Por outro lado, para o SAE e o CROSSENTROPY, utilizou-se de um menor número de iterações e valores de MAPE ainda menores do que 1%.

Pelos resultados, é possível observar que quanto maior o MAPE, maior será o erro máximo, visto a distribuição da carga não ser totalmente homogênea ao longo da curva de demanda horária (nota-se que os erros máximos se concentram principalmente no período entre as 9h e 23h, que são os pontos onde não foi utilizada a convolução temporal).

Confirmado o comportamento da rede para o dia 14 de outubro, a investigação foi voltada a outros dias atípicos do mesmo ano, desta vez com a análise focada no Natal de 1998 (25 de dezembro), mudando completamente o perfil de carga por se tratar de um feriado em um dia de sexta-feira (um dia anterior ao fim de semana).

Nesta etapa, considerou-se alterar o conjunto amostral entre um mês e três meses, bem como na quantidade prevista de dias de 1 a 3 (dias 25, 26 e 27 de dezembro), totalizando nove previsões – para cada previsão, utilizou-se como número de neurônios da camada intermediária a mesma quantidade da camada de entrada, ou seja, 24 para 1 dia, 48 para 2 dias e 72 para 3 dias. Os resultados para as previsões do Natal estão ilustrados nas Figuras 27, 28 e 29, para o Natal e o dia seguinte nas Figuras 30, 31 e 32, e para o Natal e os dois dias seguintes nas Figuras 33, 34 e 35, e seus respectivos erros máximos apresentados na Tabela 2.


Figura 27 - Previsão do Natal em um dia e um mês de amostra.



Fonte: elaborada pelo autor.

Figura 28 - Previsão do Natal em dois dias e um mês de amostra.


Previsão para o Natal e dia 26 de dezembro de 1998



Fonte: elaborada pelo autor.


Figura 29 - Previsão do Natal em três dias e um mês de amostra.

Previsão para o Natal e dias 26 e 27 de dezembro de 1998




Fonte: elaborada pelo autor.

Figura 30 - Previsão do Natal em um dia e dois meses de amostra.



Fonte: elaborada pelo autor.


Figura 31 - Previsão do Natal em dois dias e dois meses de amostra.



Fonte: elaborada pelo autor.

Figura 32 - Previsão do Natal em três dias e dois meses de amostra.


Previsão para o Natal e dias 26 e 27 de dezembro de 1998



Fonte: elaborada pelo autor.

Figura 33 - Previsão do Natal em um dia e três meses de amostra.


Previsão para o Natal de 1998



Fonte: elaborada pelo autor.

Figura 34 - Previsão do Natal em dois dias e três meses de amostra.


Previsão para o Natal e dia 26 de dezembro de 1998



Fonte: elaborada pelo autor.

Figura 35 - Previsão do Natal em três dias e três meses de amostra.

Previsão para o Natal e dias 26 e 27 de dezembro de 1998



Fonte: elaborada pelo autor.

Tabela 2 - Resultados para a alteração do período amostral.

Dias previstos	Amostras	MAPE (%)	Erro máximo (%)	Hora Emax (h)	Iterações
1 dia	1 mês	0,09	1,89	16	1
	2 meses	0,01	0,15	16	2
	3 meses	0,67	2,27	8	1
2 dias	1 mês	0,27	5,60	18	5
	2 meses	0,02	0,28	31	2
	3 meses	0,24	7,15	8	5
3 dias	1 mês	0,19	4,18	52	5
	2 meses	0,52	8,01	21	5
	3 meses	0,90	17,27	26	5

Fonte: elaborada pelo autor.

Analisando as previsões para um dia e dois dias, o MAPE apresentou um crescimento conforme foi aumentado o conjunto de amostras de 1 mês para 3 meses (assim como o erro máximo), e para 2 meses há uma diminuição em relação a 1 mês, confirmando que a melhor sazonalidade está presente em amostras de 2 meses subsequentes, possuindo informações o suficiente para determinar a característica da carga.


A melhora do MAPE (diminuição) na transição de um mês para dois meses acontece porque o final do mês de dezembro é um período de transição de estações (primavera e verão) e apresenta maior sazonalidade dos dados com características de cargas diárias semelhantes para os dias de sexta-feira, já a piora do MAPE para o aumento em três meses de amostras é devido ao período possuir menor sazonalidade, com maior quantidade de curvas de carga diárias de características divergentes. Embora este comportamento ocorra para previsões de um a dois dias, o mesmo não pode ser dito para a previsão de três dias, possuindo um significativo aumento do MAPE, mas este resultado já era esperado, uma vez que a rede deveria prever uma quantidade maior de dias considerando as informações fornecidas (maior horizonte de previsões).

Se observada a quantidade de iterações necessárias para alcançar os resultados com o menor erro possível, verifica-se que, a partir de dois dias para previsão, a rede não consegue atingir o limite de 5% de erro máximo para até 5 iterações. Há, neste caso, a perda de capacidade de convergência do algoritmo usado para treinamento em trabalhar com estes dados ao utilizar uma rede maior, ocorrendo mais pontos de máximo e de mínimo locais, bem como na presença de “vales” e “picos” de demanda em certos pontos da curva de carga, já que a rede analisa padrões comportamentais entre as amostras diárias e entre as horas de cada dia. Ao

considerar horizontes de previsão maiores, a rede levou um tempo considerável para finalização do treinamento, passando de 20 segundos de treinamento completo para previsões de um dia para mais de 30 minutos de treinamento em cada iteração para previsões de dois ou três dias.


Finalizada a etapa de investigação do Natal para diferentes períodos amostrais, realizou-se a investigação da influência da taxa de treinamento sobre as previsões da rede NARX, e desta vez usando como base de dados o dia 21 de abril, sendo feriado nacional de Tiradentes e em uma terça-feira, alterando significativamente o perfil comportamental da carga. Utilizou-se para as previsões taxas de treinamento de 70%, 80% e 90%, com respectivas taxas de validação e teste de 15%, 10% e 5%, com os resultados obtidos apresentados nas Figuras 36, 37 e 38 para a previsão do dia 21 de abril, nas Figuras 39, 40 e 41 para a previsão dos dias 21 e 22 de abril, e nas Figuras 42, 43 e 44 para a previsão dos dias 21, 22 e 23 de abril, com os dados de erros presentes na Tabela 3.

Figura 36 - Previsão para Tiradentes em um dia e 15% validação.




Fonte: elaborada pelo autor.

Figura 37 - Previsão para Tiradentes em dois dias e 15% validação.




Fonte: elaborada pelo autor.

Figura 38 - Previsão para Tiradentes em três dias e 15% validação.




Fonte: elaborada pelo autor.

Figura 39 - Previsão para Tiradentes em um dia e 10% validação.




Fonte: elaborada pelo autor.

Figura 40 - Previsão para Tiradentes em dois dias e 10% validação.




Fonte: elaborada pelo autor.

Figura 41 - Previsão para Tiradentes em três dias e 10% validação.




Fonte: elaborada pelo autor.

Figura 42 - Previsão para Tiradentes em um dia e 5% validação.




Fonte: elaborada pelo autor.

Figura 43 - Previsão para Tiradentes em dois dias e 5% validação.



Fonte: elaborada pelo autor.

Figura 44 - Previsão para Tiradentes em três dias e 5% validação.



Fonte: elaborada pelo autor.

Tabela 3 - Resultados para as previsões do feriado de Tiradentes.

Dias previstos	Dados usados para Treinamento (%)	MAPE (%)	Erro máximo (%)	Hora Emax (h)	Iterações
1 dia	70	0,35	1,48	20	4
	80	0,04	0,67	2	8
	90	0,30	4,86	7	11
2 dias	70	1,42	16,59	2	4
	80	2,57	23,32	48	1
	90	0,02	0,84	47	2
3 dias	70	1,27	10,10	55	2
	80	0,91	10,47	71	1
	90	0,44	8,98	2	1

Fonte: elaborada pelo autor.

Dos resultados apresentados da tabela, verifica-se que para previsões de um dia a precisão se torna maior em 80% dos dados usados para treinamento e o erro máximo diminui drasticamente, mas sendo necessário mais iterações e com maior quantidade de pontos destoantes do esperado (pois a rede passa a utilizar uma parcela maior das amostras para validação, buscando obter melhor precisão). Para 90% dos dados usados para treinamento, o MAPE e o erro máximo aumentam em mais do que o dobro considerando 70% dos dados para treinamento, porém, com menos pontos apresentando divergência em relação à carga original.


Para dois dias de previsão, ocorre algo inesperado: embora seja necessário menos iterações e a quantidade de pontos com erros mais expressivos seja maior (por aumentar a quantidade de dias para previsão), o MAPE e o erro máximo aumentam para a alteração de 70% para 80% dos dados para treinamento, enquanto para a alteração de 90% deste parâmetro o MAPE e o erro máximo sofrem uma diminuição abrupta (menos de 1%). Tal resposta pode ser explicada pelo fato de ter sido utilizado uma maior quantidade de informações do banco de dados para treinamento da rede, melhorando o ajuste dos pesos sinápticos e aumentando significativamente a precisão, mas com menor categorização (menor validação) frente à presença de mais curvas de carga de características parecidas (um efeito muito similar ao trabalho direto nas entradas com o banco de dados amostral).

Para a previsão de três dias, por ter uma curva de carga maior (com mais pontos semelhantes, apresentando certa periodicidade), o MAPE é reduzido de forma aproximadamente linear, enquanto o erro máximo não sofre muitas alterações e é

necessário menos iterações (como esperado ao aumentar a porcentagem de dados para treinamento e a quantidade de dias para previsão).

Como última etapa de investigação, foi utilizado como base de dados o dia 12 de outubro (dia de Nossa Senhora Aparecida), compreendendo uma segunda-feira e, por ser início de semana contendo um feriado, o perfil comportamental da carga apresenta uma característica bem diferente dos outros feriados de Natal e Tiradentes. Utilizou-se para as previsões porcentagens de dados para treinamento de 90% e dois meses de amostra, de um a três dias (dias previstos de 12, 13 e 14 de outubro consecutivamente), com os resultados obtidos apresentados nas Figuras 45, 46 e 47, com os dados de erros presentes na Tabela 4.


Figura 45 - Previsão para N. S. Aparecida em um dia.
Previsão para o Dia de Nossa Senhora Aparecida de 1998



Fonte: elaborada pelo autor.

Figura 46 - Previsão para N. S. Aparecida em dois dias.


Previsão para o Dia de Nossa Senhora Aparecida e dia 13 de outubro de 1998



Fonte: elaborada pelo autor.

Figura 47 - Previsão para N. S. Aparecida em três dias.

Previsão para o Dia de Nossa Senhora Aparecida e dias 13 e 14 de outubro de 1998



Fonte: elaborada pelo autor.

Tabela 4 - Resultados para as previsões do feriado de N.S. Aparecida.

Dias previstos	MAPE (%)	Erro máximo (%)	Hora Emax (h)	Iterações
1 dia	0,0699	0,1857	7	2
2 dias	0,1442	1,1238	15	3
3 dias	0,1941	4,0733	20	5

Fonte: elaborada pelo autor.

Pelos resultados obtidos para o dia de N. S. Aparecida, e baseando-se nas observações para as previsões dos demais feriados estudados, a rede consegue obter melhores respostas para períodos amostrais de 2 meses e 90% dos dados para

treinamento, com o MAPE e o erro máximo aumentando ao considerar mais dias para previsão e com mais iterações, sendo um comportamento parecido com o obtido das previsões de Tiradentes. Neste sentido, a melhor estrutura a ser considerada para este tipo de banco de dados é com a utilização percentuais de dados para treinamento de 90%, 5% para validação e 5% para teste, para um banco amostral de dois meses, de previsões mais precisas com um ou dois dias – embora possa ser usada para três dias ou mais, desde que se utilize um banco de dados maior contendo maior sazonalidade das cargas para efeitos de identificação de característica.

Para uma visão mais geral acerca das previsões realizadas para os feriados do Natal, N. S. Aparecida e Tiradentes, os principais resultados estão apresentados na Tabela 5, contendo os erros máximos com suas respectivas horas e MAPE, bem como o número de iterações para repetição do treinamento até alcançar o limite de 15 iterações (5 para dois e três dias de previsão) ou o erro máximo de 5%.

Tabela 5 - Resultados resumidos para as previsões dos feriados estudados.

Quant. Dias	Data	MAPE (%)	Erro máximo (%)	Hora	Iterações
1 dia	Natal	0,0077	0,1482	16	2
	N.S.Aparecida	0,0699	0,1857	7	2
	Tiradentes	0,2985	4,8567	7	15
2 dias	Natal	0,0164	0,2844	31	2
	N.S.Aparecida	0,1442	1,1238	15	3
	Tiradentes	0,0201	0,8425	47	2
3 dias	Natal	0,5197	8,0100	21	5
	N.S.Aparecida	0,1941	4,0733	20	5
	Tiradentes	0,4352	8,9815	2	5

Fonte: elaborada pelo autor.

Como pode ser observado pelos dados apresentados pela tabela e levando em consideração as observações realizadas a respeito do aumento da taxa de treinamento e do banco de dados amostrais, uma boa previsão utilizando a rede NARX para cargas elétricas pode ser obtida se levado em consideração o perfil comportamental da carga ao longo do período amostral. No entanto, deve-se ter o cuidado para não utilizar um banco de dados com muitas divergências nas curvas de carga diárias de forma semanal (principalmente em meses com maior ocorrência de feriados, em especial aos de meio de semana), podendo acarretar a “parada” do treinamento (ou seja, não ocorrência da convergência da saída). Isto ocorre porque o algoritmo de Levenberg-Marquardt possui o problema de cair em pontos de mínimo

locais durante o ajuste de pesos nas épocas subsequentes. Como forma de contornar este tipo de situação na rede NARX, pode-se considerar a implementação de outro método de cálculo de erro, se a aplicação não requerer alta precisão nos resultados, ou ainda utilizar uma porcentagem de dados para treinamento entre 70% e 80% para bancos de dados maiores.

6 CONCLUSÃO

Tendo em vista o desempenho da rede frente aos diferentes tipos de análise realizadas, ao observar o MAPE em cada um dos resultados previstos, conclui-se que a influência do banco de dados como entrada da rede para amostras possui consequência direta nos dados fornecidos pela rede NARX considerando as respostas obtidas após o treinamento e teste.

Por terem sido considerados dias de feriados para previsão, o desafio de obter erros máximos dentro da faixa de 5% a 10% se tornou muito maior se comparados com dias normais do ano, uma vez que a variabilidade da carga ao longo de um dia de feriado, como fora estudado para Natal, Tiradentes e N. S. Aparecida, é mais acentuada do que em dias de quarta-feira e quinta-feira, por exemplo (há uma maior quantidade de “vales” e “picos” de demanda, contendo maior variação não apenas nas amostras ao longo do período como também na curva de carga do próprio dia selecionado para previsão). Neste sentido, notou-se que, mesmo apresentando uma curva de carga atípica e não cíclica, a rede NARX possui elevada precisão, com valores de MAPE menores do que 0,01% na maioria dos casos, principalmente por considerar na primeira etapa do treinamento para ajuste inicial dos pesos os valores de carga original do dia alvo, com o uso do algoritmo de Levenberg-Marquardt (embora a arquitetura disponibilize outros dois métodos de treinamento para bancos de dados maiores ou de resposta mais rápida).

No que diz respeito ao trabalho direto com o banco de dados para diferentes amostras, afirma-se que uma maior extensão temporal das amostras não necessariamente melhora a precisão dos resultados da rede, já que há a presença de mais padrões com diferentes características para as curvas de carga ao longo do período selecionado (menor sazonalidade), dificultando a determinação de um perfil comportamental e impedindo melhor precisão. Contudo, mesmo com tal dificuldade, possui um grau de incerteza muito menor se consideradas as previsões realizadas para períodos mais curtos (um dia), e por permitir alterar a sua estrutura com relação ao método de cálculo do erro, tipo de treinamento, quantidade dos dados para treino, validação e teste, tempo de atraso (delay, em segundos) e quantidade de neurônios da camada escondida, ela se estabelece como uma rede versátil e adaptável para diferentes aplicações na previsão de séries temporais com perfil mais caótico (graças ao uso da função não linear no ajuste dos pesos).

Para o caso estudado, considerados os dias de feriado escolhidos, os melhores resultados na previsão da curva de demanda diária são obtidos para uma rede estruturada com 24 neurônios na camada intermediária, tempo de atraso de 2 segundos, uso como métrica de erro o MSE, treinamento via Levenberg-Marquardt, porcentagem dos dados para treinamento de 90%, 5% para validação e 5% para teste, subconjunto amostral de 2 meses subsequentes, e previsão máxima de 2 dias com erros máximos na faixa de 1% a 10%, com MAPE menor do que 0,05%.

No caso de serem realizadas previsões para períodos mais longos, deve-se haver maior atenção e cuidado quanto às entradas da rede, observando a sazonalidade da carga para que a saída possua resultados coerentes com relação aos valores originais para o dia a ser previsto.

Como sugestões para possíveis trabalhos futuros, podem ser utilizados como entradas meses correspondentes a diferentes anos, ao invés de meses subsequentes de um mesmo ano, bem como o uso da pluviosidade como variável substituindo as estações do ano para a comparação da curva de demanda prevista em períodos de maior escassez de chuvas.

REFERÊNCIAS

- ALCÂNTARA, Isaque F. P. **Deteção e classificação de distúrbios em qualidade de energia usando modelos NARX neurais**. 2020. Dissertação (Mestrado em Engenharia de Sistemas e Automação) — Universidade Federal de Lavras, Lavras, 2020.
- ALHANOUTI, Muhammed; GAUTERIN, Frank. **Predicting the torque demand of a battery electric vehicle for real-world driving maneuvers using the NARX technique**. World Electric Vehicle Journal, v. 15, n. 3, p. 103, 2024. DOI: <https://doi.org/10.3390/wevj15030103>.
- ANDRADE, Luciano C. M.; OLESKOVICZ, Mario; SANTOS, Athila Q.; COURRY, Denis V.; FERNANDES, Ricardo A. S. **Very short-term load forecasting based on NARX recurrent neural networks**. In: 2014 IEEE PES General Meeting | Conference & Exposition, National Harbor, MD, USA, 27–31 July 2014. p. 1-5. DOI: 10.1109/PESGM.2014.6939012.
- BEZERRA, Erick C.; DO REGO, Marcos C. O.; BRAGA, Arthur P. de S. **et al. Comparação entre modelos estatísticos e redes neurais usando persistência como referência para a previsão da velocidade do vento**. In: X SBAI – Simpósio Brasileiro de Automação Inteligente, São João del-Rei, MG, 18–21 set. 2011.
- BUITRAGO, Jaime; ASFOUR, Shihab. **Short-term forecasting of electric loads using nonlinear autoregressive artificial neural networks with exogenous vector inputs**. Energies, v. 10, n. 1, p. 40, 2017. DOI: 10.3390/en10010040.
- CAMPOS, Lidio M. L. **Modelos não lineares recorrentes com capacidade de extrapolação: um estudo para predição do índice de preços ao consumidor (IPC-BR)**. In: IX Simpósio de Excelência em Gestão e Tecnologia (SEGeT), Castanhal, PA, 2012.
- DE PAULA, Matheus; COLNAGO, Marilaine; CASACA, Wallace. **Redes neurais MLP e NARX aplicadas na previsão da velocidade do vento em parques eólicos do estado da Bahia**. Proceeding Series of the Brazilian Society of Computational and Applied Mathematics, v. 7, n. 1, 2020.
- FRANÇA, Ana C. G.; FACEROLI, Silvana T.; NASCIMENTO, Paulo S. C. **et al. Análise comparativa de modelos de previsão de geração de energia eólica baseados em machine learning**. Revista de Sistemas e Computação, v. 9, n. 2, p. 348-358, jul./dez. 2019.
- HAYKIN, Simon. **Neural networks and learning machines**. Porto Alegre: Bookman, 2001.
- KAMINSKI, Antônio M.; MEDEIROS, Leonardo H.; BUENO, Daniela M. **et al. Emprego de rede neural artificial para predição de temperatura de topo de óleo em transformador de potência**. SBSE – Sociedade Brasileira de Sistemas Elétricos, v. 1, n. 1, p. 2146, ano não informado. DOI: 10.48011/sbse.v1i1.2146.

KOPIER, Alberto A.; SILVA, Victor N. A. S.; OLIVEIRA, Luiz A. A. et al. **Redes neurais artificiais e suas aplicações no setor elétrico**. Revista de Engenharias da Faculdade Salesiana, n. 9, p. 27-33, 2019.

LEITE, Francisco E. A. **Aplicação de redes neurais artificiais na previsão de curto prazo da carga nodal de sistemas de energia elétrica**. 1997. Dissertação (Mestrado) — Universidade Estadual de Campinas, Campinas, 1997.

LEONTARITIS, I. J. and Billings, S. A. (1985a). **Input-output parametric models for nonlinear systems part I: Deterministic nonlinear systems**. Int. J. Control, 41(2):303328.

LEONTARITIS, I. J. and Billings, S. A. (1985b). **Input-output parametric models for nonlinear systems part II: Stochastic nonlinear systems**. Int. J. Control, 41(2):329344.

NEVES, Danilo P.; RODRIGUES, Lucas M. R.; MONTEIRO, Raul V. A. et al. **Desenvolvimento de interface em Matlab para previsão do comportamento de um sistema elétrico com penetração fotovoltaica utilizando inteligência artificial**. XIV CEEL, Uberlândia, MG, 2016.

O'DONOVAN, T. M. **Short Term Forecasting: An introduction to the Box-Jenkins approach**. John Wiley & Sons, New York, 1983.

OLATUNDE, Tosin M.; OKWANDU, Azubuike C.; AKANDE, Dorcas O. et al. **The impact of smart grids on energy efficiency: a comprehensive review**. Engineering Science & Technology Journal, v. 5, n. 4, 2024. DOI: 10.51594/estj/v5i4.1016.

PASCANU, Razvan; MIKOLOV, Tomas; BENGIO, Yoshua. **On the difficulty of training recurrent neural networks**. In: International Conference on Machine Learning, 2013. p. 1310-1318.

PEREIRA, Fabio Henrique et al. **Nonlinear autoregressive neural network models for prediction of transformer oil-dissolved gas concentrations**. Energies, v. 11, n. 7, p. 1691, 2018.

ROSENBLATT, F. **The perceptron: A probabilistic model for information storage and organization in the brain**. Psychological Review, Vol. 65, pp. 386-408, 1958.

RUMELHART, D. E.; HINTON, G. E. and WILLIAMS, R. J. **Learning representations by Back-propagation errors**. Nature, No. 323, pp. 533-536, 1986.

RUSSELL, Stuart; NORVIG, Peter. **Artificial intelligence: a modern approach**. 3rd ed. Upper Saddle River: Prentice Hall, 2009.

SHENVI, Nayana; VIRANI, Hassanali G. **Prediction of ionospheric total electron content data using NARX neural network model**. Bulletin of Electrical Engineering and Informatics, v. 13, n. 1, p. 548-558, Feb. 2024. DOI: 10.11591/eei.v13i1.6506.

VILELA, Leticia B.; MATEUS, Tiago H. A. **Aplicação de rede neural NARX para a previsão do preço da soja.** In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 36., 2016, João Pessoa. Anais [...]. João Pessoa: ABEPRO, 2016.

WERBOS, P. J. **Beyond regression: New tools for prediction and analysis in the behavioral sciences.** Master Thesis, Harvard University, 1974.

WIDROW, B. and LEHR, M. A. **30 years of adaptive neural networks: perceptron, madaline, and backpropagation.** Proceedings of the IEEE, Vol. 78, No. 9, pp. 1415-1442, 1990.

XIE, Hang; TANG, Hao; LIAO, Yu-He. **Time series prediction based on NARX neural networks: an advanced approach.** In: 2009 International Conference on Machine Learning and Cybernetics, Hebei, China, 2009. p. 1275-1279. DOI: 10.1109/ICMLC.2009.5212326.

ZUAZO, Irati Z.; BOUSSAADA, Zina; AGINAKO, Naiara et al. **Short-term load forecasting of building electricity consumption using NARX neural networks model.** In: 2021 6th International Conference on Smart and Sustainable Technologies (SpliTech), Bol & Split, Croatia, 2021. p. 1-6. DOI: 10.23919/SpliTech52315.2021.9566440.

ANEXO – MATRIZ DE DADOS DE CARGA

Data	Dia	Mês	Ano	Dia da semana	Estação do ano	Pluviosidade
01/01/1998	1	1	1998	5	1	0
02/01/1998	2	1	1998	6	1	23,1
03/01/1998	3	1	1998	7	1	5,9
04/01/1998	4	1	1998	1	1	18,1
05/01/1998	5	1	1998	2	1	14,3
06/01/1998	6	1	1998	3	1	6
07/01/1998	7	1	1998	4	1	22,4
08/01/1998	8	1	1998	5	1	29,3
09/01/1998	9	1	1998	6	1	29,1
10/01/1998	10	1	1998	7	1	16,9
11/01/1998	11	1	1998	1	1	26,7
12/01/1998	12	1	1998	2	1	23,5
13/01/1998	13	1	1998	3	1	0
14/01/1998	14	1	1998	4	1	18,8
15/01/1998	15	1	1998	5	1	0
16/01/1998	16	1	1998	6	1	11,7
17/01/1998	17	1	1998	7	1	0
18/01/1998	18	1	1998	1	1	20,1
19/01/1998	19	1	1998	2	1	16,9
20/01/1998	20	1	1998	3	1	24,9
21/01/1998	21	1	1998	4	1	7
22/01/1998	22	1	1998	5	1	1,1
23/01/1998	23	1	1998	6	1	1,4
24/01/1998	24	1	1998	7	1	0
25/01/1998	25	1	1998	1	1	22
26/01/1998	26	1	1998	2	1	1,4
27/01/1998	27	1	1998	3	1	0
28/01/1998	28	1	1998	4	1	0
29/01/1998	29	1	1998	5	1	4,2
30/01/1998	30	1	1998	6	1	14,4
31/01/1998	31	1	1998	7	1	26,3
01/02/1998	1	2	1998	1	1	0
02/02/1998	2	2	1998	2	1	9,4
03/02/1998	3	2	1998	3	1	22
04/02/1998	4	2	1998	4	1	12,6
05/02/1998	5	2	1998	5	1	0
06/02/1998	6	2	1998	6	1	0
07/02/1998	7	2	1998	7	1	27,1
08/02/1998	8	2	1998	1	1	1
09/02/1998	9	2	1998	2	1	9,6
10/02/1998	10	2	1998	3	1	0
11/02/1998	11	2	1998	4	1	7,9
12/02/1998	12	2	1998	5	1	0
13/02/1998	13	2	1998	6	1	24,2
14/02/1998	14	2	1998	7	1	0
15/02/1998	15	2	1998	1	1	3,7
16/02/1998	16	2	1998	2	1	0
17/02/1998	17	2	1998	3	1	15,1
18/02/1998	18	2	1998	4	1	12,8
19/02/1998	19	2	1998	5	1	0

20/02/1998	20	2	1998	6	1	4,6
21/02/1998	21	2	1998	7	1	5,5
22/02/1998	22	2	1998	1	1	0
23/02/1998	23	2	1998	2	1	21,4
24/02/1998	24	2	1998	3	1	8,9
25/02/1998	25	2	1998	4	1	19,5
26/02/1998	26	2	1998	5	1	5,7
27/02/1998	27	2	1998	6	1	5
28/02/1998	28	2	1998	7	1	7,1
01/03/1998	1	3	1998	1	1	0
02/03/1998	2	3	1998	2	1	3
03/03/1998	3	3	1998	3	1	28,8
04/03/1998	4	3	1998	4	1	0
05/03/1998	5	3	1998	5	1	17,7
06/03/1998	6	3	1998	6	1	24,6
07/03/1998	7	3	1998	7	1	3,7
08/03/1998	8	3	1998	1	1	18,7
09/03/1998	9	3	1998	2	1	2
10/03/1998	10	3	1998	3	1	3
11/03/1998	11	3	1998	4	1	2,7
12/03/1998	12	3	1998	5	1	9,6
13/03/1998	13	3	1998	6	1	5,3
14/03/1998	14	3	1998	7	1	8,1
15/03/1998	15	3	1998	1	1	5,9
16/03/1998	16	3	1998	2	1	18,1
17/03/1998	17	3	1998	3	1	6,2
18/03/1998	18	3	1998	4	1	27,9
19/03/1998	19	3	1998	5	1	30
20/03/1998	20	3	1998	6	1	5,3
21/03/1998	21	3	1998	7	2	29,8
22/03/1998	22	3	1998	1	2	6,1
23/03/1998	23	3	1998	2	2	13,4
24/03/1998	24	3	1998	3	2	0
25/03/1998	25	3	1998	4	2	27,2
26/03/1998	26	3	1998	5	2	7,2
27/03/1998	27	3	1998	6	2	0
28/03/1998	28	3	1998	7	2	3,9
29/03/1998	29	3	1998	1	2	0
30/03/1998	30	3	1998	2	2	13,6
31/03/1998	31	3	1998	3	2	25,9
01/04/1998	1	4	1998	4	2	0
02/04/1998	2	4	1998	5	2	16
03/04/1998	3	4	1998	6	2	0
04/04/1998	4	4	1998	7	2	10,6
05/04/1998	5	4	1998	1	2	0
06/04/1998	6	4	1998	2	2	2,3
07/04/1998	7	4	1998	3	2	0
08/04/1998	8	4	1998	4	2	6,1
09/04/1998	9	4	1998	5	2	20,8
10/04/1998	10	4	1998	6	2	0
11/04/1998	11	4	1998	7	2	22
12/04/1998	12	4	1998	1	2	16,4
13/04/1998	13	4	1998	2	2	20

14/04/1998	14	4	1998	3	2	18
15/04/1998	15	4	1998	4	2	0
16/04/1998	16	4	1998	5	2	0
17/04/1998	17	4	1998	6	2	0
18/04/1998	18	4	1998	7	2	24,1
19/04/1998	19	4	1998	1	2	0
20/04/1998	20	4	1998	2	2	15,5
21/04/1998	21	4	1998	3	2	18,7
22/04/1998	22	4	1998	4	2	17,9
23/04/1998	23	4	1998	5	2	15,7
24/04/1998	24	4	1998	6	2	24,7
25/04/1998	25	4	1998	7	2	22,5
26/04/1998	26	4	1998	1	2	3,7
27/04/1998	27	4	1998	2	2	15,3
28/04/1998	28	4	1998	3	2	11,6
29/04/1998	29	4	1998	4	2	4,5
30/04/1998	30	4	1998	5	2	0
01/05/1998	1	5	1998	6	2	22,2
02/05/1998	2	5	1998	7	2	22,6
03/05/1998	3	5	1998	1	2	28,2
04/05/1998	4	5	1998	2	2	1,6
05/05/1998	5	5	1998	3	2	0
06/05/1998	6	5	1998	4	2	18,6
07/05/1998	7	5	1998	5	2	3,6
08/05/1998	8	5	1998	6	2	0
09/05/1998	9	5	1998	7	2	29,9
10/05/1998	10	5	1998	1	2	3,9
11/05/1998	11	5	1998	2	2	4,3
12/05/1998	12	5	1998	3	2	16,8
13/05/1998	13	5	1998	4	2	29,4
14/05/1998	14	5	1998	5	2	28,8
15/05/1998	15	5	1998	6	2	5,6
16/05/1998	16	5	1998	7	2	1
17/05/1998	17	5	1998	1	2	0
18/05/1998	18	5	1998	2	2	0
19/05/1998	19	5	1998	3	2	14,6
20/05/1998	20	5	1998	4	2	0
21/05/1998	21	5	1998	5	2	24,5
22/05/1998	22	5	1998	6	2	0
23/05/1998	23	5	1998	7	2	28,4
24/05/1998	24	5	1998	1	2	7,9
25/05/1998	25	5	1998	2	2	5,3
26/05/1998	26	5	1998	3	2	1,2
27/05/1998	27	5	1998	4	2	10
28/05/1998	28	5	1998	5	2	14,1
29/05/1998	29	5	1998	6	2	6,7
30/05/1998	30	5	1998	7	2	9,2
31/05/1998	31	5	1998	1	2	0
01/06/1998	1	6	1998	2	2	19,8
02/06/1998	2	6	1998	3	2	3,4
03/06/1998	3	6	1998	4	2	13,5
04/06/1998	4	6	1998	5	2	28,8
05/06/1998	5	6	1998	6	2	7,7

06/06/1998	6	6	1998	7	2	20,6
07/06/1998	7	6	1998	1	2	0
08/06/1998	8	6	1998	2	2	0
09/06/1998	9	6	1998	3	2	29,4
10/06/1998	10	6	1998	4	2	7,2
11/06/1998	11	6	1998	5	2	15,7
12/06/1998	12	6	1998	6	2	0
13/06/1998	13	6	1998	7	2	0
14/06/1998	14	6	1998	1	2	20,9
15/06/1998	15	6	1998	2	2	27,1
16/06/1998	16	6	1998	3	2	25
17/06/1998	17	6	1998	4	2	0
18/06/1998	18	6	1998	5	2	29,8
19/06/1998	19	6	1998	6	2	0
20/06/1998	20	6	1998	7	2	0
21/06/1998	21	6	1998	1	2	7,2
22/06/1998	22	6	1998	2	3	1
23/06/1998	23	6	1998	3	3	0
24/06/1998	24	6	1998	4	3	3,1
25/06/1998	25	6	1998	5	3	0
26/06/1998	26	6	1998	6	3	0
27/06/1998	27	6	1998	7	3	0
28/06/1998	28	6	1998	1	3	17
29/06/1998	29	6	1998	2	3	24,5
30/06/1998	30	6	1998	3	3	0
01/07/1998	1	7	1998	4	3	27,5
02/07/1998	2	7	1998	5	3	26
03/07/1998	3	7	1998	6	3	8
04/07/1998	4	7	1998	7	3	0
05/07/1998	5	7	1998	1	3	0
06/07/1998	6	7	1998	2	3	1,2
07/07/1998	7	7	1998	3	3	11,2
08/07/1998	8	7	1998	4	3	27
09/07/1998	9	7	1998	5	3	23,3
10/07/1998	10	7	1998	6	3	2,5
11/07/1998	11	7	1998	7	3	1,1
12/07/1998	12	7	1998	1	3	0
13/07/1998	13	7	1998	2	3	0
14/07/1998	14	7	1998	3	3	22,8
15/07/1998	15	7	1998	4	3	0
16/07/1998	16	7	1998	5	3	0
17/07/1998	17	7	1998	6	3	7,6
18/07/1998	18	7	1998	7	3	0
19/07/1998	19	7	1998	1	3	0
20/07/1998	20	7	1998	2	3	0
21/07/1998	21	7	1998	3	3	6,6
22/07/1998	22	7	1998	4	3	0
23/07/1998	23	7	1998	5	3	5,1
24/07/1998	24	7	1998	6	3	12,8
25/07/1998	25	7	1998	7	3	0
26/07/1998	26	7	1998	1	3	3,6
27/07/1998	27	7	1998	2	3	23,3
28/07/1998	28	7	1998	3	3	16,8

29/07/1998	29	7	1998	4	3	7,2
30/07/1998	30	7	1998	5	3	0
31/07/1998	31	7	1998	6	3	10,4
01/08/1998	1	8	1998	7	3	17,5
02/08/1998	2	8	1998	1	3	24,7
03/08/1998	3	8	1998	2	3	0
04/08/1998	4	8	1998	3	3	0
05/08/1998	5	8	1998	4	3	24,8
06/08/1998	6	8	1998	5	3	0
07/08/1998	7	8	1998	6	3	16,7
08/08/1998	8	8	1998	7	3	14,9
09/08/1998	9	8	1998	1	3	0
10/08/1998	10	8	1998	2	3	11,3
11/08/1998	11	8	1998	3	3	0
12/08/1998	12	8	1998	4	3	0
13/08/1998	13	8	1998	5	3	0
14/08/1998	14	8	1998	6	3	1,1
15/08/1998	15	8	1998	7	3	2,7
16/08/1998	16	8	1998	1	3	0
17/08/1998	17	8	1998	2	3	16,4
18/08/1998	18	8	1998	3	3	18,8
19/08/1998	19	8	1998	4	3	0
20/08/1998	20	8	1998	5	3	0
21/08/1998	21	8	1998	6	3	29,4
22/08/1998	22	8	1998	7	3	26,3
23/08/1998	23	8	1998	1	3	15,5
24/08/1998	24	8	1998	2	3	25,6
25/08/1998	25	8	1998	3	3	10,7
26/08/1998	26	8	1998	4	3	24,8
27/08/1998	27	8	1998	5	3	0
28/08/1998	28	8	1998	6	3	19,4
29/08/1998	29	8	1998	7	3	0
30/08/1998	30	8	1998	1	3	0
31/08/1998	31	8	1998	2	3	6,2
01/09/1998	1	9	1998	3	3	5,2
02/09/1998	2	9	1998	4	3	10,6
03/09/1998	3	9	1998	5	3	9
04/09/1998	4	9	1998	6	3	29,8
05/09/1998	5	9	1998	7	3	11,3
06/09/1998	6	9	1998	1	3	5,4
07/09/1998	7	9	1998	2	3	0
08/09/1998	8	9	1998	3	3	15,1
09/09/1998	9	9	1998	4	3	0
10/09/1998	10	9	1998	5	3	0
11/09/1998	11	9	1998	6	3	11,7
12/09/1998	12	9	1998	7	3	17,5
13/09/1998	13	9	1998	1	3	20
14/09/1998	14	9	1998	2	3	0
15/09/1998	15	9	1998	3	3	28,2
16/09/1998	16	9	1998	4	3	0
17/09/1998	17	9	1998	5	3	7,1
18/09/1998	18	9	1998	6	3	0
19/09/1998	19	9	1998	7	3	0


20/09/1998	20	9	1998	1	3	17,6
21/09/1998	21	9	1998	2	3	12,8
22/09/1998	22	9	1998	3	3	15,3
23/09/1998	23	9	1998	4	3	13,3
24/09/1998	24	9	1998	5	4	0
25/09/1998	25	9	1998	6	4	0
26/09/1998	26	9	1998	7	4	10
27/09/1998	27	9	1998	1	4	26,9
28/09/1998	28	9	1998	2	4	0
29/09/1998	29	9	1998	3	4	18
30/09/1998	30	9	1998	4	4	19,4
01/10/1998	1	10	1998	5	4	14,7
02/10/1998	2	10	1998	6	4	15,6
03/10/1998	3	10	1998	7	4	20,3
04/10/1998	4	10	1998	1	4	18,2
05/10/1998	5	10	1998	2	4	28,8
06/10/1998	6	10	1998	3	4	2,3
07/10/1998	7	10	1998	4	4	0
08/10/1998	8	10	1998	5	4	5,4
09/10/1998	9	10	1998	6	4	11,5
10/10/1998	10	10	1998	7	4	0
11/10/1998	11	10	1998	1	4	23,2
12/10/1998	12	10	1998	2	4	10,3
13/10/1998	13	10	1998	3	4	17,6
14/10/1998	14	10	1998	4	4	22,2
15/10/1998	15	10	1998	5	4	26,1
16/10/1998	16	10	1998	6	4	23,8
17/10/1998	17	10	1998	7	4	0
18/10/1998	18	10	1998	1	4	10,3
19/10/1998	19	10	1998	2	4	0
20/10/1998	20	10	1998	3	4	0
21/10/1998	21	10	1998	4	4	24,8
22/10/1998	22	10	1998	5	4	25,8
23/10/1998	23	10	1998	6	4	24,7
24/10/1998	24	10	1998	7	4	22,5
25/10/1998	25	10	1998	1	4	26,3
26/10/1998	26	10	1998	2	4	19,4
27/10/1998	27	10	1998	3	4	28
28/10/1998	28	10	1998	4	4	23,4
29/10/1998	29	10	1998	5	4	1
30/10/1998	30	10	1998	6	4	0
31/10/1998	31	10	1998	7	4	17,9
01/11/1998	1	11	1998	1	4	16,4
02/11/1998	2	11	1998	2	4	29,7
03/11/1998	3	11	1998	3	4	27,4
04/11/1998	4	11	1998	4	4	0
05/11/1998	5	11	1998	5	4	15,8
06/11/1998	6	11	1998	6	4	3,1
07/11/1998	7	11	1998	7	4	6,3
08/11/1998	8	11	1998	1	4	0
09/11/1998	9	11	1998	2	4	20,7
10/11/1998	10	11	1998	3	4	25,4
11/11/1998	11	11	1998	4	4	27,2

12/11/1998	12	11	1998	5	4	0
13/11/1998	13	11	1998	6	4	4,7
14/11/1998	14	11	1998	7	4	0
15/11/1998	15	11	1998	1	4	0
16/11/1998	16	11	1998	2	4	23,4
17/11/1998	17	11	1998	3	4	27,5
18/11/1998	18	11	1998	4	4	22,7
19/11/1998	19	11	1998	5	4	0
20/11/1998	20	11	1998	6	4	13,8
21/11/1998	21	11	1998	7	4	0
22/11/1998	22	11	1998	1	4	0
23/11/1998	23	11	1998	2	4	9,7
24/11/1998	24	11	1998	3	4	19,7
25/11/1998	25	11	1998	4	4	23,9
26/11/1998	26	11	1998	5	4	27,3
27/11/1998	27	11	1998	6	4	0
28/11/1998	28	11	1998	7	4	7
29/11/1998	29	11	1998	1	4	25,4
30/11/1998	30	11	1998	2	4	0
01/12/1998	1	12	1998	3	4	24,5
02/12/1998	2	12	1998	4	4	1,4
03/12/1998	3	12	1998	5	4	12,6
04/12/1998	4	12	1998	6	4	11,9
05/12/1998	5	12	1998	7	4	0
06/12/1998	6	12	1998	1	4	16,4
07/12/1998	7	12	1998	2	4	0
08/12/1998	8	12	1998	3	4	0
09/12/1998	9	12	1998	4	4	20,4
10/12/1998	10	12	1998	5	4	15,7
11/12/1998	11	12	1998	6	4	0
12/12/1998	12	12	1998	7	4	9,9
13/12/1998	13	12	1998	1	4	5
14/12/1998	14	12	1998	2	4	0
15/12/1998	15	12	1998	3	4	10,6
16/12/1998	16	12	1998	4	4	13,8
17/12/1998	17	12	1998	5	4	0
18/12/1998	18	12	1998	6	4	10,5
19/12/1998	19	12	1998	7	4	0
20/12/1998	20	12	1998	1	4	25,7
21/12/1998	21	12	1998	2	4	0
22/12/1998	22	12	1998	3	4	14
23/12/1998	23	12	1998	4	1	11,8
24/12/1998	24	12	1998	5	1	0
25/12/1998	25	12	1998	6	1	3,9
26/12/1998	26	12	1998	7	1	14,1
27/12/1998	27	12	1998	1	1	21,5
28/12/1998	28	12	1998	2	1	0
29/12/1998	29	12	1998	3	1	7,1
30/12/1998	30	12	1998	4	1	15,5
31/12/1998	31	12	1998	5	1	5,2

APÊNDICE A – DEMAIS GRÁFICOS PARA OS RESULTADOS APRESENTADOS DE CADA CASO ESTUDADO

- Dia 1 de fevereiro:


Figura 48 - Erro para a previsão de carga do primeiro dia de fevereiro.



Fonte: elaborada pelo autor.

- Dia 1 de março:


Figura 49 - Erro para a previsão de carga do primeiro dia de março.



Fonte: elaborada pelo autor.

- Dia 1 de abril:


Figura 50 - Erro para a previsão de carga do primeiro dia de abril.



Fonte: elaborada pelo autor.

- Dia 1 de abril (3 meses):


Figura 51 - Erro para a previsão de carga do primeiro dia de abril (usando 3 meses).



Fonte: elaborada pelo autor.


- Dia 14 de outubro corrigido com erro mais acentuado:

Figura 52 - Predição da carga para o dia 14 de outubro em tempo real.



Fonte: elaborada pelo autor.

Figura 53 - Erro para a previsão da carga de 14 de outubro.




Fonte: elaborada pelo autor.

Previsões de Natal:


Uso de uma a três meses nas amostras de entrada:

Figura 54 - Erro para a previsão de carga no Natal (1 dia, 1 mês).




Fonte: elaborada pelo autor.

Figura 55 - Predição da carga para o dia 25 de dezembro (1 dia, 1 mês).




Fonte: elaborada pelo autor.

Figura 56 - Erro para a previsão de carga no Natal (1 dia, 2 meses).




Fonte: elaborada pelo autor.

Figura 57 - Predição da carga para o dia 25 de dezembro (1 dia, 2 meses).




Fonte: elaborada pelo autor.

Figura 58 - Erro para a previsão de carga no Natal (1 dia, 3 meses).




Fonte: elaborada pelo autor.

Figura 59 - Predição da carga para o dia 25 de dezembro (1 dia, 3 meses).




Fonte: elaborada pelo autor.

Figura 60 - Erro para a previsão de carga no Natal (2 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 61 - Predição da carga para o dia 25 de dezembro (2 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 62 - Erro para a previsão de carga no Natal (2 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 63 - Predição da carga para o dia 25 de dezembro (2 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 64 - Erro para a previsão de carga no Natal (2 dias, 3 meses).




Fonte: elaborada pelo autor.

Figura 65 - Predição da carga para o dia 25 de dezembro (2 dias, 3 meses).




Fonte: elaborada pelo autor.

Figura 66 - Erro para a previsão de carga no Natal (3 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 67 - Predição da carga para o dia 25 de dezembro (3 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 68 - Erro para a previsão de carga no Natal (3 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 69 - Predição da carga para o dia 25 de dezembro (3 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 70 - Erro para a previsão de carga no Natal (3 dias, 3 meses).



Fonte: elaborada pelo autor.

Figura 71 - Predição da carga para o dia 25 de dezembro (3 dias, 3 meses).




Fonte: elaborada pelo autor.

Previsões de Tiradentes:


Uso de 70% a 90% dos dados para treinamento:

Figura 72 - Erro para a previsão de carga de Tiradentes (1 dia, 70%).




Fonte: elaborada pelo autor.

Figura 73 - Predição da carga para o dia 21 de abril (1 dia, 70%).




Fonte: elaborada pelo autor.

Figura 74 - Erro para a previsão de carga de Tiradentes (1 dia, 80%).




Fonte: elaborada pelo autor.

Figura 75 - Predição da carga para o dia 21 de abril (1 dia, 80%).




Fonte: elaborada pelo autor.

Figura 76 - Erro para a previsão de carga de Tiradentes (1 dia, 90%).




Fonte: elaborada pelo autor.

Figura 77 - Predição da carga para o dia 21 de abril (1 dia, 90%).




Fonte: elaborada pelo autor.

Figura 78 - Erro para a previsão de carga de Tiradentes (2 dias, 70%).




Fonte: elaborada pelo autor.

Figura 79 - Predição da carga para o dia 21 de abril (2 dias, 70%).




Fonte: elaborada pelo autor.

Figura 80 - Erro para a previsão de carga de Tiradentes (2 dias, 80%).




Fonte: elaborada pelo autor.

Figura 81 - Predição da carga para o dia 21 de abril (2 dias, 80%).




Fonte: elaborada pelo autor.

Figura 82 - Erro para a previsão de carga de Tiradentes (2 dias, 90%).




Fonte: elaborada pelo autor.

Figura 83 - Predição da carga para o dia 21 de abril (2 dias, 90%).




Fonte: elaborada pelo autor.

Figura 84 - Erro para a previsão de carga de Tiradentes (3 dias, 70%).




Fonte: elaborada pelo autor.

Figura 85 - Predição da carga para o dia 21 de abril (3 dias, 70%).




Fonte: elaborada pelo autor.

Figura 86 - Erro para a previsão de carga de Tiradentes (3 dias, 80%).




Fonte: elaborada pelo autor.

Figura 87 - Predição da carga para o dia 21 de abril (3 dias, 80%).




Fonte: elaborada pelo autor.

Figura 88 - Erro para a previsão de carga de Tiradentes (3 dias, 90%).



Fonte: elaborada pelo autor.

Figura 89 - Predição da carga para o dia 21 de abril (3 dias, 90%).




Fonte: elaborada pelo autor.

Previsões de N. S. Aparecida:


Uso de um a três meses de amostras de entrada:

Figura 90 - Erro para a previsão de carga de N. S. Aparecida (1 dia, 1 mês).




Fonte: elaborada pelo autor.

Figura 91 - Predição da carga para o dia de N. S. Aparecida (1 dia, 1 mês).




Fonte: elaborada pelo autor.

Figura 92 - Erro para a previsão de carga de N. S. Aparecida (1 dia, 2 meses).




Fonte: elaborada pelo autor.

Figura 93 - Predição da carga para o dia de N. S. Aparecida (1 dia, 2 meses).




Fonte: elaborada pelo autor.

Figura 94 - Erro para a previsão de carga de N. S. Aparecida (1 dia, 3 meses).




Fonte: elaborada pelo autor.

Figura 95 - Predição da carga para o dia de N. S. Aparecida (1 dia, 3 meses).




Fonte: elaborada pelo autor.

Figura 96 - Erro para a previsão de carga de N. S. Aparecida (2 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 97 - Predição da carga para o dia de N. S. Aparecida (2 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 98 - Erro para a previsão de carga de N. S. Aparecida (2 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 99 - Predição da carga para o dia de N. S. Aparecida (2 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 100 - Erro para a previsão de carga de N. S. Aparecida (2 dias, 3 meses).




Fonte: elaborada pelo autor.

Figura 101 - Predição da carga para o dia de N. S. Aparecida (2 dias, 3 meses).




Fonte: elaborada pelo autor.

Figura 102 - Erro para a previsão de carga de N. S. Aparecida (3 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 103 - Predição da carga para o dia de N. S. Aparecida (3 dias, 1 mês).




Fonte: elaborada pelo autor.

Figura 104 - Erro para a previsão de carga de N. S. Aparecida (3 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 105 - Predição da carga para o dia de N. S. Aparecida (3 dias, 2 meses).




Fonte: elaborada pelo autor.

Figura 106 - Erro para a previsão de carga de N. S. Aparecida (3 dias, 3 meses).



Fonte: elaborada pelo autor.

Figura 107 - Predição da carga para o dia de N. S. Aparecida (3 dias, 3 meses).




Fonte: elaborada pelo autor.

APÊNDICE B – ANÁLISE DOS PERÍODOS AMOSTRAIS ESCOLHIDOS PARA ENTRADA NA REDE NARX (CONSIDERANDO DIA DA SEMANA E ESTAÇÃO DO ANO NO PRIMEIRO TRIMESTRE)

- Previsão 1 de fevereiro (domingo de verão)

Amostras de janeiro:

Figura 108 – Dias da semana em análise para janeiro.




Fonte: elaborada pelo autor.

- Previsão 1 de março (domingo de verão)

Amostras de fevereiro:

Figura 109 – Dias da semana para análise em fevereiro.




Fonte: elaborada pelo autor.

- Previsão 1 de abril (quarta de outono)

Amostras de março:

Figura 110 – Dias da semana em análise para março.



Fonte: elaborada pelo autor.