UNIVERSIDADE FEDERAL DA PARAÍBA CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Sharon Raphaella Oliveira Simões de Sousa

Metodologia para Previsão de Demanda com Influência da Temperatura e Chuvas utilizando Técnicas de Inteligência Artificial

> João Pessoa Dezembro - 2020

Sharon Raphaella Oliveira Simões de Sousa

Metodologia para Previsão de Demanda com Influência da Temperatura e Chuvas utilizando Técnicas de Inteligência Artificial

Trabalho de Conclusão de Curso apresentado à Universidade Federal da Paraíba como exigência para a obtenção do título de Bacharel em Engenharia Elétrica.

Universidade Federal da Paraíba Centro de Energias Alternativas e Renováveis Curso de Graduação em Engenharia Elétrica

Orientador: Prof. Juan M. Mauricio Villanueva

João Pessoa Dezembro - 2020

Catalogação na publicação Seção de Catalogação e Classificação

S725m Sousa, Sharon Raphaella Oliveira Simões de. Metodologia para previsão de demanda com influência da temperatura e chuvas utilizando técnicas de inteligência artificial / Sharon Raphaella Oliveira Simões de Sousa. - João Pessoa, 2020. 59 f. : il. Orientador: Juan Moises Mauricio Villanueva. TCC (Graduação) - UFPB/CEAR. 1. Redes neurais artificiais. 2. Energia elétrica previsão de demanda. 3. Energia elétrica - temperatura. I. Villanueva, Juan Moises Mauricio. II. Título. UFPB/CT

Elaborado por CARLOS AUGUSTO ROLIM DA SILVA JUNIOR - CRB-PB-000618/0

Metodologia para Previsão de Demanda com Influência da Temperatura e Chuvas utilizando Técnicas de Inteligência Artificial

Trabalho de Conclusão de Curso apresentado à Universidade Federal da Paraíba como exigência para a obtenção do título de Bacharel em Engenharia Elétrica.

Trabalho Aprovado. João Pessoa, 14 de dezembro de 2020:

Prof. Juan M. Mauricio Villanueva Orientador

Prof. Helon David de Macêdo Braz Examinador

Prof. Rogério Gaspar de Almeida Examinador

> João Pessoa Dezembro - 2020

Agradecimentos

Agradeço primeiramente a Deus e Jesus Cristo, por nunca me abandonarem. Eles sabem tudo que passei para chegar até aqui.

Agradeço, com todo meu amor e admiração, a minha mãe *Maria Valdete*, a ela eu devo tudo, sem ela eu não seria metade do que sou hoje. Agradeço imensamente ao seu apoio, ensinamentos, esforço, batalha, compreensão, paciência e carinho comigo ao longo desta trajetória e que me permitiu estudar e chegar ao final deste graduação, este diploma eu devo imensamente a ela.

Agradeço ao meu noivo, por toda ajuda, apoio, compreensão, cuidado, carinho e paciência comigo ao longo deste caminho.

Agradeço ao meu pequeno companheiro de todos os dias e noites, que esteve sempre comigo nas minhas madrugadas de estudos, meu pequeno Snoopy.

Agradeço ao meu orientador Prof. Juan, por acreditar em mim, pelo apoio, compreensão e orientação neste trabalho, nas disciplinas e atividades acadêmicas, o senhor teve um papel muito importante para minha formação acadêmica.

Agradeço aos professores que contribuíram para minha formação, Prof. Waslon, Prof. Alexandre, Prof. Rogério, e demais professores.

Agradeço aos meus amigos de fora da universidade, pela motivação, palavras de apoio e por acreditarem em mim ao longo desta trajetória.

Agradeço aos meus amigos da universidade pela convivência e ajuda.

Por fim, a todos os que contribuíram direta ou indiretamente para a realização deste trabalho.

A verdadeira coragem é ir atrás de seu sonho mesmo quando todos dizem que ele é impossível. (Cora Coralina)

Resumo

Os estudos relacionados a previsão de demanda de energia elétrica são importantes para empresas do ramo de energia elétrica, pois existe a necessidade de alocação de recursos com antecedência, exigindo um planejamento a médio e longo prazos. Para estimar a previsão, recursos computacionais foram utilizados para servir como apoio as empresas de energia elétrica. Com a utilização do software MATLAB[®] e técnicas computacionais baseadas em redes artificias neurais, simulações foram realizadas para estimar uma previsão de demanda de energia com a utilização de dados de temperatura e pluviométricos (chuvas), e incluindo também dados de energia. Para tornar a previsão de demanda mais próxima possível da curva de saída objetivo, é importante incluir variáveis que possuam uma correlação mais favoráveis com a potência, neste projeto a inclusão de dados temperatura, dados pluviométricos (chuvas) e energia foram estudadas com a finalidade de determinar suas relações e influências sobre a previsão de demanda de energia. Os dados de temperatura e dados pluviométricos (chuvas) locais foram obtidos pelo site da INMET (Instituto Nacional de Meteorologia) e os dados de demanda de energia obtidos através de uma concessionária de energia. Para a previsão de demanda, foram considerados os anos de 2011, 2012 e 2013 para os dados de potência, temperatura, chuva e energia.

Palavras-chave: Redes neurais artificiais. Previsão de demanda. Previsão com temperatura.

Abstract

Studies related to forecasting electricity demand are important for electric power companies, as there is a need to allocate resources in advance, requiring medium and long-term planning. To estimate the forecast, computational resources were used to support the electricity companies. Using the MATLAB[®] software and computational techniques based on artificial neural networks, simulations were performed to estimate a forecast of energy demand using temperature and pluviometric data (rain), and also including energy data. To make the demand forecast as close as possible to the objective output curve, it is important to include variables that have a more favorable correlation with power. In this project, the inclusion of temperature, pluviometric (energy) and energy data were studied in order determine their relationships and influences on forecasting energy demand. Local temperature data and pluviometric (rain) data were obtained from the INMET (National Institute of Meteorology) website and energy demand data obtained from an energy utility. For the forecast of demand, the years 2011, 2012 and 2013 were considered for the data of power, temperature, rain and energy.

Keywords: Artificial neural networks. Demand forecasting. Forecast with temperature.

Lista de ilustrações

Figura 1 –	Mapa do Sistema de Transmissão - Horizonte 2024	18
Figura 2 –	Mapa Dinâmico do SIN: Sistemas Isolados	18
Figura 3 –	Sistema Elétrico de Potência	20
Figura 4 –	Diagrama unifilar simplificado de uma subestação	21
Figura 5 –	Modelo simplificado da série temporal	24
Figura 6 –	Modelo não-linear de um neurônio	26
Figura 7 –	Diagrama unifilar simplificado de uma subestação	30
Figura 8 –	Diagrama para a Previsão de demanda	31
Figura 9 –	Entradas e Saídas da RNA de estudo	32
Figura 10 –	Modelo da RNA com entradas e saídas	34
Figura 11 –	Rede MPL com duas camadas ocultas	36
Figura 12 –	Neural Network Training do MATLAB [®]	36
Figura 13 –	Realimentação da previsão no processo de validação e teste	38
Figura 14 –	Curvas de saída para menor MAPE com $Traingd \in Trainlm \ldots \ldots$	41
Figura 15 –	Curvas de saída para menor ERRO relativo com $Traingd$ e $Trainlm$.	41
Figura 16 –	Comportamento do MAPE para <i>Trainlm</i>	42
Figura 17 –	Comportamento do MAPE para <i>Traingd</i>	42
Figura 18 –	Curvas de saída para menor MAPE com Traingd e Trainlm	43
Figura 19 –	Curvas de saída para menor ERRO com $Traingd$ e $Trainlm$	44
Figura 20 –	Comportamento do MAPE para <i>Trainlm</i>	44
Figura 21 –	Comportamento do MAPE para <i>Traingd</i>	45
Figura 22 –	Curvas de saída para menor MAPE com Traingd e Trainlm	46
Figura 23 –	Curvas de saída para menor ERRO com $Traingd$ e $Trainlm$	46
Figura 24 –	Comportamento do MAPE para <i>Trainlm</i>	47
Figura 25 –	Comportamento do MAPE para <i>Traingd</i>	47
Figura 26 –	Curvas de saída para menor MAPE com Traingd e Trainlm	48
Figura 27 –	Curvas de saída para menor ERRO com $Traingd$ e $Trainlm$	49
Figura 28 –	Comportamento do MAPE para <i>Trainlm</i>	49
Figura 29 –	Comportamento do MAPE para <i>Traingd</i>	50
Figura 30 –	Curvas de saída para menor MAPE com Traingd e Trainlm	51
Figura 31 –	Curvas de saída para menor ERRO com $Traingd$ e $Trainlm$	51
Figura 32 –	Comportamento do MAPE para <i>Trainlm</i>	52
Figura 33 –	Comportamento do MAPE para <i>Traingd</i>	52
Figura 34 –	Curvas de saídas das melhores RNAs	53

Lista de tabelas

Tabela 1 –	Resultado para menor MAPE com <i>Traingd</i> e <i>Trainlm</i>	40
Tabela 2 –	Resultado para menor ERRO com <i>Traingd</i> e <i>Trainlm</i>	40
Tabela 3 –	Resultado para menor MAPE com $Traingd \in Trainlm \ldots \ldots \ldots$	43
Tabela 4 –	Resultado para menor ERRO com <i>Traingd</i> e <i>Trainlm</i>	43
Tabela 5 –	Resultado para menor MAPE com $Traingd \in Trainlm \ldots \ldots \ldots$	45
Tabela 6 –	Resultado para menor ERRO com <i>Traingd</i> e <i>Trainlm</i>	45
Tabela 7 $-$	Resultado para menor MAPE com $Traingd \in Trainlm \ldots \ldots$	48
Tabela 8 –	Resultado para menor ERRO com <i>Traingd</i> e <i>Trainlm</i>	48
Tabela 9 –	Resultado para menor MAPE com $Traingd \in Trainlm \ldots \ldots$	50
Tabela 10 –	Resultado para menor ERRO com <i>Traingd</i> e <i>Trainlm</i>	50
Tabela 11 –	Resultado final das RNAs	53

Lista de abreviaturas e siglas

ANEEL	Agência Nacional de Energia Elétrica
BP	BackPropagation
ETs	Estações Transformadoras
FFBP	Feed-forward BackPropagation
IA	Inteligência Artifical
INMET	Instituto Nacional de Meteorologia
LMS	Least Mean Square error
MAPE	Mean Absolute Percentage Error
MLP	Multilayer Perceptron
RNA	Rede Neural Artificial
ONS	Operador Nacional do Sistema Elétrico
SCADA	Supervisory Control and Data Acquisition
SEs	Subestações
SEP	Sistema Elétrico de Potência
SIN	Sistema Interligado Nacional

Lista de símbolos

- φ
 Letra grega minúscula Fi
- Σ
 Letra grega maiúscula Sigma
- ρ
 Letra grega minúscula Rô

Sumário

1	INTRODUÇÃO	13
1.1	Pertinência e motivação do trabalho	13
1.2	Objetivos	15
1.3	Organização do trabalho	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Sistemas Elétricos de Potência	17
2.2	Séries temporais	22
2.3	Redes Neurais Artificiais	24
2.3.1	O neurônio artificial	25
2.3.2	Modelo de rede neural	27
2.3.3	Aplicações de Previsão de Demanda com RNA	29
3	PREVISÃO DE DEMANDA DE ENERGIA	30
3.1	Objeto de estudo	30
3.2	Implementação do Banco de dados	31
3.2.1	Banco de Dados	33
3.3	Treinamento da RNA	34
3.4	Parâmetros de treinamento da RNA	35
3.5	Teste e validação da RNA	37
3.6	Cálculo da Correlação	38
4	RESULTADOS	40
4.1	Análise dos Resultados	40
4.2	Redes com Potência como entrada	40
4.3	Redes com Potência e Temperatura como entradas	43
4.4	Redes com Potência, Temperatura e Energia como entradas	45
4.5	Redes com Potência, Temperatura e Chuva como entradas	48
4.6	Redes com Potência, Temperatura, Chuva e Energia como entradas	50
4.7	Discussão sobre os resultados	53
5	CONCLUSÕES	55
	REFERÊNCIAS	56

1 Introdução

1.1 Pertinência e motivação do trabalho

A estimativa de valores futuros de uma série temporal pode ser aplicada em diversas áreas, como economia (mercado de ações, taxas de inflação, juros de investimento e taxas de câmbio), clima (temperatura, chuva, neve e vento) e indústria (gerenciamento da cadeia de suprimentos), demanda de produtos e preços de matérias-primas) (MORAES et al., 2013).

O consumo de energia é um critério econômico fundamental, que expressa o desenvolvimento industrial de uma cidade ou de um país. O aumento da demanda futura de energia requer determinação correta da quantidade de energia fornecida (KAFAZI; BANNARI; ABOUABDELLAH, 2016).

As estimativas das necessidades futuras de energia são necessárias para resolver uma variedade de tarefas relacionadas com o desenvolvimento da economia e da esfera social do país e suas regiões (FILIPPOV; GRYGORIEVA; MAKAROVA, 2018).

Demanda de energia é o valor de energia elétrica que a unidade consumidora utilizará para realizar suas operações.

A previsão de demanda é um instrumento essencial na operação confiável e econômica de sistemas de energia. Dependendo do horizonte temporal, a previsão de demanda pode geralmente ser dividida em curto, médio e longo prazo (MAO et al., 2009).

Empresas de distribuição de energia elétrica precisam enviar relatórios periódicos de previsões de demanda das cargas localizadas em sua área de concessão, nos horizontes definidos pelo Operador Nacional do Sistema (ONS) e pela Empresa de Pesquisa Energética (EPE) (RIBEIRO et al., 2006). Além dos estudos de previsão, é necessário realizar estudos internos, com o objetivo de planejar as decisões de operação, controle e manutenção de seus sistemas. Os recursos que exigem uma antecedência na alocação, podem ser a aquisição e construção de novas linhas de transmissão, a compra de equipamentos, manutenções programadas e a compra e venda de energia.

A previsão a longo prazo possui como horizonte o período de anos ou décadas, e objetiva o planejamento para incrementar a capacidade das linhas de transmissão ou construção de novas plantas de geração.

A previsão de demanda a médio prazo, que ocorre no prazo de semana a meses, permite às concessionárias e empresas de energia elétrica alocar seus recursos como: manutenções nas redes elétricas, a compra de equipamentos, expansão do seu sistema, estratégias no mercado de energia (GHIASSI; ZIMBRA; SAIDANE, 2006) e (PAN; LEE, 2012).

A previsão de carga de curto prazo, variando de uma hora a uma semana, é importante para funções como comprometimento da unidade, despacho de emissão econômica, programação de transferência de energia e controle em tempo real (MAO et al., 2009). A previsão de carga de curto prazo pode ter impacto na programação em tempo real, melhorando a confiabilidade do sistema de energia, otimizando os custos operacionais e as implicações financeiras do mercado (PERÇUKU; MINKOVSKAB; STOYANOVAC, 2018).

Segundo (KARAYIANNIS; BALASUBRAMANIAN; MALKI, 2003) os seguintes aspectos foram destacados a respeito da previsão de demanda:

- Distribuição econômica das unidades geradoras;
- Intercâmbio de energia entre empresas;
- Programação da produção, que pode resultar em economia para os consumidores;
- Redução do consumo;
- Distribuição da poluição ambiental;

Para um planejamento da distribuição, a definição de um horizonte é preciso. Em uma visão de longo prazo, este deve ser de cinco a dez anos, se aproximando do limite superior para a rede de transmissão e subestações, e do limite inferior para a rede de distribuição. Isso se justifica pelo tempo de maturação das obras de transmissão e subestação e das obras na rede de distribuição. A atualização destes planos deve ser anual, de forma a permitir ao regulador e à sociedade acompanhar as mudanças de tendências nos investimentos, bem como, comparar o que foi planejado e o que foi efetivamente implementado, considerando, naturalmente, as motivações e barreiras de caráter econômico, financeiro, estrutural, organizacional, legal, ambiental, etc (SANTOS; HADDAD; CRUZ, 2008). Os estudos de previsão de demanda tem o objetivo de auxiliar nesta atualização anual do plano de expansão (MEDEIROS, 2016).

Com a tentativa de buscar uma melhor exatidão nos resultados de previsão, vários métodos estão sendo desenvolvidos, adaptados e aprimorados ao longo do tempo. Anteriormente ao surgimento da inteligência artificial, apenas os métodos estatísticos e probabilísticos, liderados pelos modelos Box e Jenkins (BOX et al., 2016) eram aplicados em séries temporais para previsão. Com o desenvolvimento de técnicas computacionais, que levavam vantagem diante da não linearidade dos dados e sem depender de complexos modelos matemáticos, métodos de inteligência artificial passaram a ser utilizados em previsão de demanda (MEDEIROS, 2019). Contudo, apesar dos métodos mencionados anteriormente, ao seu modo, trazerem resultados satisfatórios, as técnicas citadas continuam sendo aperfeiçoadas objetivando melhorar cada vez mais a exatidão e confiabilidade da previsão. Com isso, os resultados podem vir a ser utilizados como ferramentas de auxílio no planejamento da alocação dos recursos no setor elétrico.

O clima é a variável independente mais importante para a previsão de carga (FAHAD; ARBAB, 2014).

A temperatura pode ser uma variável poderosa no desenvolvimento de estudos, pois em regiões com altas temperaturas normalmente fazem uso de sistemas de refrigeração para ambientes, o que implica no aumento do consumo de energia elétrica, com picos de demanda específicos durante o dia. Dessa forma, o estudo da previsão de demanda, ao levar em conta tais particularidades, estabelece um enfoque estratégico acerca da área em estudo, possibilitando a verificação das influências que devem ser ponderadas (MEDEIROS, 2019).

1.2 Objetivos

O objetivo deste trabalho é apresentar uma metodologia para previsão de demanda de energia considerando a influência de variáveis externas, com a utilização de técnicas de inteligência artificial. Dentre os métodos de Inteligência Artificial (IA), será implementado o método de Redes Neurais Artificiais (RNA), onde fatores como potência, temperatura, chuva e energia serão as entradas desta RNA.

A previsão de demanda deste trabalho, consiste no modelo a curto prazo. Por meio da utilização do software MATLAB[®], dois algoritmos de treinamento de rede são utilizados, sendo eles *traingd* e *trainlm*. A entrada da RNA, consistirá de combinações de amostras passadas da potência, temperatura, chuva e energia que serão simulados para cada algoritmo de rede.

1.3 Organização do trabalho

Este trabalho foi estruturado em cinco capítulos e referências.

O segundo capítulo, será feito uma fundamentação teórica e serão abordados os temas a respeito do Sistema Elétrico de Potência, como as características dos sistemas de geração, transmissão e distribuição de energia elétrica. Conceitos relacionados ao de séries temporais e métodos estatísticos baseados em inteligência artificial também serão apresentados. Finalizando o segundo capítulo, será abordado o tema sobre Redes Neurais Artificiais, explicando as principais considerações sobre o tema que será aplicado ao trabalho.

O terceiro capítulo abordará a metodologia de previsão de demanda utilizada, iniciando com a descrição do objeto de estudo, em seguida, será exposto a forma de implementação do banco de dados, treinamento da RNA e seus parâmetros, com a fundamentação dos testes e da validação da Rede Neural. Por fim, o tópico sobre a correlação é apresentado.

O quarto capítulo, serão apresentados os resultados. Para este capitulo, subseções serão apresentadas para cada termo de estudo com a finalidade de melhor apresentação dos resultados. Gráficos e tabelas serão apresentados para cada simulação e resultado obtido.

O quinto capítulo constará das conclusões do trabalho, analisando e comparando os resultados das combinações de temperatura, chuva e energia como variável de entrada da RNA em conjunto com amostras de potência passadas.

Por último, constará as referências abordadas neste trabalho.

2 Fundamentação teórica

2.1 Sistemas Elétricos de Potência

Os sistemas elétricos de potência tem como função essencial a de fornecer energia elétrica aos usuários com a qualidade adequada, no instante que for solicitada. Portanto os sistemas tem a função de produtor, transformando a energia eólica, mecânica, térmica ou outra forma de energia em energia elétrica, e a de distribuidor, fornecendo aos consumidores a quantidade de energia demandada. Não sendo possível seu armazenamento o sistema elétrico deve contar com uma capacidade de produção e transporte que supra, em determinado período de tempo, de energia consumida e à máxima solicitação instantânea de potência ativa. Portanto, é preciso um sistema de controle da produção de modo que a cada instante seja produzida a energia necessária a atender à demanda e às perdas na produção e no transporte (KAGAN; OLIVER; ROBBA, 2005).

No Brasil, a principal fonte de geração é a hidrelétrica (água corrente dos rios), que corresponde por 62% da capacidade instalada em operação no país, seguida das termelétricas (gás natural, carvão mineral, combustíveis fósseis, biomassa e nuclear), com 28%. O restante é proveniente de usinas eólicas (energia dos ventos) e importação da energia de outros países (ANEEL, 2020).

O sistema elétrico brasileiro permite o intercâmbio da energia produzida em todas as regiões, exceto em sistemas isolados. O trânsito da energia é possível graças ao Sistema Interligado Nacional (SIN), uma grande rede de transmissão com mais de 100 mil quilômetros (km) de extensão. As localidades do sistema isolado vêm sendo gradativamente interligadas ao longo dos anos, hoje somente cerca de 2% do mercado nacional permanece no sistema isolado (ANEEL, 2020).

Sistemas isolados são sistemas elétricos de serviço público de distribuição de energia elétrica que, em sua configuração normal, não estejam eletricamente conectados ao Sistema Interligado Nacional - SIN, por razões técnicas ou econômicas (EPE, 2020b). Segundo (EPE, 2020a) existem 250 sistemas isolados no Brasil, a maioria deles situam-se na região Norte.

O ONS é o órgão responsável pelo controle da operação e pela coordenação do SIN, sob regulamentação e fiscalização da ANEEL.

Na Figura 1 é apresentado o SIN para o horizonte 2024. Na Figura 2, os Sistemas Isolados do Brasil.



Figura 1 – Mapa do Sistema de Transmissão - Horizonte 2024

Fonte: Adaptado de (ONS, 2020).



Figura 2 – Mapa Dinâmico do SIN: Sistemas Isolados

Fonte: Adaptado de (ONS, 2020).

A geração de energia elétrica se faz através de variadas tecnologias, onde as principais consistem em máquinas rotativas, geradores síncronos ou alternadores, utilizando turbinas hidráulicas, a vapor ou eólicas. A energia elétrica obtida via usinas hidrelétricas encontra-se no topo da matriz energética brasileira, devido aos grandes recursos hídricos distribuídos ao longo de boa parte do território. As demais fontes que compõem tal matriz, são: energia solar, eólica, entre outras (MEDEIROS, 2016).

Conforme (KAGAN; OLIVER; ROBBA, 2005) os sistemas elétricos de potência podem ser subdivididos em três grandes grupos:

- Geração: A energia elétrica é obtida pela conversão de alguma outra forma de energia, utilizando-se máquinas rotativa, geradores síncronos ou alternadores, do qual o conjugado mecânico é obtido através de um processo que, que normalmente utiliza-se turbinas hidráulicas ou a vapor. Para o caso hidráulico, o potencial disponível é definido pela queda d'água, altura da queda e vazão, podendo-se ter usinas desde algumas dezenas de MW até milhares de MW. Para o caso de usinas térmicas, que se baseiam da conversão de calor em energia elétrica, há aquelas em que o vapor que é produzido em uma caldeira, pela queima do combustível, aciona uma turbina a vapor que fornece o conjugado motor ao alternador.
- **Transmissão**: Parte responsável pelo transporte da energia elétrica dos centros de produção aos de consumo;
- **Distribuição**: Responsável pela distribuição da energia elétrica recebida do sistema de transmissão aos grandes, médios e pequenos consumidores.

Um modelo representativo do SEP é apresentado na Figura 3, com a geração, transmissão, distribuição e comercialização. As geradoras produzem a energia, as transmissoras a transportam do ponto de geração até os centros consumidores, de onde as distribuidoras a levam até a casa dos cidadãos. As comercializadoras, sendo empresas autorizadas a comprar e vender energia para os consumidores livres (geralmente consumidores que precisam de maior quantidade de energia) (ANEEL, 2020).



Figura 3 – Sistema Elétrico de Potência

Fonte: Adaptado de (ANEEL, 2020).

O sistema de distribuição pode ser dividido em cinco parte (KAGAN; OLIVER; ROBBA, 2005). Essas divisões são:

- Sistema de subtransmissão: este tem a função de captar a energia das subestações de transmissão e transferi-la para as subestações de distribuição e aos consumidores em tensão de subtransmissão, usualmente, 138 kV ou 69 kV ou, mais raramente, em 34,5 kV, com capacidade de transporte de algumas dezenas de MW por circuito, usualmente de 20 a 150MW. Os consumidores em tensão de subtransmissão são representados, usualmente, por grandes instalações industriais, estações de tratamento e bombeamento de água.
- Subestações de Distribuição: São suprimidas pela rede de subtransmissão, são responsáveis pela transformação da tensão de subtransmissão para a de distribuição primária.
- Sistema de distribuição primária: As redes de distribuição primária, ou de média tensão, emergem das subestações (SEs) de distribuição e operam, no caso da rede aérea, radialmente, com possibilidade de transferência de blocos de carga entre circuitos para o atendimento da operação em condições de contingência, devido à manutenção corretiva ou preventiva. Os troncos dos alimentadores empregam, usualmente, condutores de seção 336,4 MCM (0.5067mm2) permitindo, na tensão de 13,8 kV, o transporte de potência máxima de cerca de 12 MVA, que, face à necessidade de transferência de blocos de carga entre alimentadores, fica limitada a cerca de 8 MVA. Estas redes atendem aos consumidores primários e aos transformadores de distribuição, estações transformadoras, ETs, que suprem a rede secundária, ou de baixa tensão. Dentre os consumidores primários destacam-se indústrias de porte médio, conjuntos comerciais ("shopping centers"), instalações de iluminação pública,

etc. Podem ser aéreas ou subterrâneas, as primeiras de uso mais difundido, pelo seu menor custo, e as segundas, encontrando grande aplicação em áreas de maior densidade de carga, por exemplo zona central de uma metrópole, ou onde há restrições paisagísticas.

- Estações Transformadoras: As ETs, são construídas por transformadores, que reduzem a tensão primária, ou média tensão, para a de distribuição secundária, ou baixa tensão.
- Redes de distribuição secundárias: Das ETs, deriva-se a rede de baixa tensão, 220V/127 V ou 380V/220 V, que pode operar em malha ou radial e que supre os consumidores de baixa tensão, consumidores residenciais, pequenos comércios e indústrias. Alcança, por circuito, comprimentos da ordem de centenas de metros. Destaca-se o predomínio, nesta rede, de consumidores residenciais.

A natureza de cada segmento do sistema irá definir o grau de confiabilidade por ele exigido, dependendo da potência transportada. Evidentemente, nesta hierarquia de confiabilidade, o elemento do topo e a SE de subtransmissão, encarregada da transferência de potência na ordem de centenas de MVA, e o último desta escala é formado pela rede de baixa tensão, onde a potência é na ordem de dezenas de kVA (MEDEIROS, 2019).

As subestações de distribuição, que rebaixam o nível de tensão para 13,8 kV e fornecem energia elétrica a rede de distribuição primária "alimentam"parte da rede de distribuição, dessa maneira, os circuitos de saída dessas subestações são denominados de alimentadores (MEDEIROS, 2016). Na Figura 4 é representado o diagrama unifilar de uma subestação de distribuição que abaixa o nível de tensão de 69 kV para 13,8 kV e possui 5 alimentadores na saída.



Figura 4 – Diagrama unifilar simplificado de uma subestação

Fonte: Elaborado pela autora, 2020.

As subestações de distribuição de energia são monitoradas por um Sistema de Aquisição de Dados (SCADA - Supervisory Control and Data Acquisition) que coleta dados de natureza elétrica (tensão, corrente, fator de potência, etc.), de diferentes pontos de medição localizados em equipamentos (disjuntores e religadores) e barramentos (ME-DEIROS, 2016). Os dados obtidos por estas medições são enviados para um servidor que irá armazenar em um banco de dados. Essas medições que são realizadas ao longo do tempo com periodicidade de 15 minutos, são denominadas *séries temporais*.

2.2 Séries temporais

Uma série temporal é uma sequência de observações feitas sequencialmente no tempo. Muitos conjuntos de dados aparecem como séries temporais: uma sequência mensal da quantidade de mercadorias expedidas de uma fábrica, uma série semanal do número de acidentes rodoviários, quantidade diária de chuvas, observações de hora em hora feito no rendimento de um processo químico e assim por diante (BOX et al., 2016). Diversas áreas, como economia, engenharia e ciências naturais, usam as séries temporais para prever comportamentos e tomar decisões (MEDEIROS et al., 2016).

Uma característica essencial de uma série temporal são, normalmente, que as observações adjacentes são dependentes. A natureza dessa dependência entre as observações de uma série de tempo é de considerável interesse prático. A análise de séries temporais preocupa-se com técnicas para a análise desta dependência. Isso requer o desenvolvimento de modelos estocásticos e dinâmicos para dados de séries temporais e o uso de tais modelos em áreas importantes de aplicação (BOX et al., 2016).

A seguir, o uso dessas séries temporais e modelos dinâmicos em cinco importantes áreas de aplicação (BOX et al., 2016).

- A *previsão* de valores futuros de uma série temporal a partir de valores atuais e passados.
- A determinação da *função de transferência* de um sistema sujeito à inércia a determinação de um modelo dinâmico de entrada saída que pode mostrar o efeito na saída de um sistema de qualquer série de entradas.
- O uso de variáveis de entrada do indicador em modelos de função de transferência para representar e avaliar os efeitos de eventos de *intervenção* incomuns no comportamento de uma série temporal.
- O exame das inter-relações entre várias variáveis de séries temporais relacionadas de interesse e a determinação de modelos dinâmicos *multivariados* apropriados para representar essas relações conjuntas entre as variáveis ao longo do tempo.

• O projeto de esquemas de *controle simples* por meio dos quais desvios potenciais da saída do sistema de um alvo desejado podem, na medida do possível, ser compensados pelo ajuste dos valores de série de entrada.

Com relação a previsão de séries temporais, o uso do tempo t de observações disponíveis de uma série temporal para prever seu valor em algum momento futuro t + l pode fornecer uma base para:

- Planejamento econômico e de negócios;
- Planejamento de produção;
- Estoque e controle de produção;
- Controle e otimização de processos industriais.

A decomposição é usada em séries temporais para descrever a tendência e os fatores sazonais em uma série temporal (PERÇUKU; MINKOVSKAB; STOYANOVAC, 2018).

Uma etapa importante na seleção de um método de previsão apropriado é considerar os tipos de padrões de dados, de forma que os métodos mais apropriados para esses padrões possam ser utilizados, quatro tipos de padrões de dados de série temporal podem ser distinguidos: horizontal, sazonal, cíclico, e tendência (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998), cujas definições são:

- Um padrão *horizontal* (H) existe quando os valores dos dados flutuam em torno de uma média constante. (Essa série é chamada de "estacionária"em sua média.).
- Um padrão *sazonal* (S) existe quando uma série é influenciada por fatores sazonais. As séries sazonais às vezes também são chamadas de "periódicas", embora não se repitam exatamente ao longo de cada período.
- Um padrão *cíclico* (C) existe quando a exibição de dados aumenta e quedas que não sejam de período fixo.
- Um padrão de *tendência* (T) existe quando há um aumento ou diminuição de longo prazo nos dados

A principal distinção entre um padrão sazonal e um padrão cíclico é que o primeiro tem uma duração constante e se repete em uma base periódica regular, enquanto o último varia em duração. Além disso, a duração média de um ciclo costuma ser maior do que a sazonalidade e a magnitude de um ciclo costuma ser mais variável do que a sazonalidade. A previsão de carga tem um impacto significativo nos custos de operação e produção da concessionária de energia elétrica. Portanto, uma grande variedade de métodos de previsão foi proposta, a maioria dos quais geralmente pode ser classificada em duas grandes categorias: métodos estatísticos e métodos baseados em inteligência artificial (IA) (MAO et al., 2009).

A partir de séries temporais podemos realizar a previsão de valores futuros com valores atuais e passados, Na Figura 5 é apresentado um modelo ilustrativo de uma série temporal, onde (k-n) são valores de amostras passadas e (k+n) são amostras de valores futuros, para n=1,2,3,.



Figura 5 – Modelo simplificado da série temporal

Fonte: Elaborado pela autora, 2020.

Para a modelagem da previsão de uma série temporal, processos estatísticos como auto-regressivo (AR), média móvel (MA) e média auto-regressiva-mista móvel (ARMA) são utilizados.

Dentre os métodos de inteligência artificial (IA), podemos citar as Redes Neurais Artificias (RNA), Lógica Fuzzy e Algoritmos genéticos. Sendo a RNA utilizada neste trabalho.

2.3 Redes Neurais Artificiais

Os primeiros registros de estudos sobre a neurocomputação datam a década de 40, do qual, sugeriam a construção de uma máquina baseada no cérebro humano (FURTADO, 2019).

Os trabalhos com RNAs, ou redes neurais, é um ramo bastante estudado e aprofundado, devido a complexidade de se aproximar de como o cérebro processa as informações.

Como um ramo da inteligência artificial, a rede neural artificial é uma disciplina emergente que tem se desenvolvido rapidamente nos últimos anos (HONG, 2011). Uma rede neural é composta por um elevado número de processadores, os neurônios, amplamente interligados através de conexões com um determinado valor que estabelece o grau de conectividade entre estes, denominado peso da conexão ou sinapse (FURTADO, 2019).

O cérebro é uma estrutura complexa, não-linear e paralelo, que funciona organizando seus constituintes estruturais (*neurônios*), de forma a realizar certos processamentos muito mais rápidos que computadores (HAYKIN, 2001). Essas características proporcionam, entre outras, a grande habilidade de reconhecimento e generalização de padrões. Essa habilidade é a grande motivadora para o desenvolvimento de Redes Neurais Artificiais (RNA) (MEDEIROS et al., 2016).

Pode-se definir uma rede neural do seguinte modo, sendo vista como uma máquina adaptativa (HAYKIN, 2001):

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido

2.3.1 O neurônio artificial

Um *neurônio* é um elemento fundamental de unidade de processamento de informação da rede neural. De acordo com a Figura 6, é apresentado três elementos básicos para o modelo neural:

- **Sinapses:** Um conjunto de sinapses, onde cada uma é constituída por um peso. De acordo com a figura 6, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . Onde k se refere ao neurônio analisado e j está atrelado ao terminal de entrada da sinapse do peso em questão. Diferente da sinapse cerebral, o peso sináptico poderá estar contido em um intervalo onde existem valores negativos e positivos.
- **Somador:** Irá somar os sinais de entrada, ponderados pelas devidas sinapses do neurônio; as operações aqui descritas formam uma combinação linear.
- **Função de Ativação:** Limitar a amplitude de saída do neurônio. Também conhecida como função restritiva, pois restringe o intervalo permissível da amplitude do sinal

de saída para um valor finito. O intervalo normalizado de amplitude de saída de um neurônio é expresso como um intervalo unitário fechado [0,1] ou, de forma alternativa, [-1,1]. Existem alguns tipos básico de Função de Ativação: Função de Limiar, Função Linear por partes, Função Sigmóide e Função tangente hiperbólica.



Figura 6 – Modelo não-linear de um neurônio

Fonte: Adaptado de (HAYKIN, 2001).

Onde,

- $x_1, x_2, ..., x_m$: Sinais de entrada;
- $w_{k1}, w_{k2}, ..., w_{km}$: são os pesos sinápticos do neurônio k;
- u_k : Saída do combinador linear devido aos sinais de entrada;
- b_k : bias;
- $\varphi(.)$: Função de ativação;
- y_k : Neurônio de saída.

Em termos de equações matemáticas, um neurônio k pode ser descrito como:

$$u_k = \sum_{j=1}^m w_{kj} x_j \tag{2.1}$$

е

$$y_k = \varphi(u_k + b_k) \tag{2.2}$$

O **bias** (b_k) tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, a depender se for positivo ou negativo.

A *Função de Ativação*, de acordo com (MACRINI, 2000), pode ser dividida em três principais funções mais utilizadas:

Sigmóides e Tangentes hiperbólicas: (ou Tan-Sigmoid (DEMUTH; BEALE, 1994)), A função Sigmóide é a função de ativação mais utilizada. Esta função tem a propriedade de aliar uma região quase linear à característica de saturação, além de ser diferenciável e não decrescente. É representada pela seguinte equação:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \tag{2.3}$$

Onde a > 0, é o parâmetro de inclinação da função sigmóide.

A função tangente hiperbólica possui as mesmas características da função sigmóide, mas opera no intervalo (-a,+a) e não no intervalo (0,a). Representada pela equação:

$$\varphi(v) = tanh(v) \tag{2.4}$$

 Lineares: A função linear é muito utilizada em neurônio nas camadas de saída da rede, quando não se deseja o efeito de saturação das funções sigmoide e tangente hiperbólica. Representada pela equação:

$$\varphi(v) = av \tag{2.5}$$

• Radiais: As funções radiais, que na verdade são gaussianas, são fundamentadas nas redes de bases de funções radiais.Representada pela equação:

$$\varphi(v) = e^{-v^2} \tag{2.6}$$

A maneira como os neurônios de uma rede neural estão estruturados está familiarmente ligado com o algoritmo de aprendizado usado para treinar a RNA, com isso os algoritmos usados no projeto de redes neurais podem ser chamados de estruturados. De modo geral, podemos classificar três tipos de estruturas: 1) Redes alimentadas adiante com camada única, 2) Redes alimentadas diretamente com múltiplas camadas e 3) Redes recorrentes.

2.3.2 Modelo de rede neural

Redes Perceptrons de múltiplas camadas (MLP) constituem uma importante classe de redes neurais artificiais, e possuem diversas aplicações (PAN; LEE, 2012). As redes MLP vêm sendo aplicadas na resolução de diversos problemas, por meio de um algoritmo conhecido como algoritmo de retropropagação (*backpropagation*). Os pesos sinápticos são ajustados para que a resposta real da rede se mova para mais próximo da resposta almejada, numa lógica estatística. O processo de aprendizagem realizado com o algoritmo é denominado aprendizagem por retropropagação.

Como a regra de aprendizagem do perceptron, o algoritmo de erro quadrático mínimo (LMS - *least mean square error*) é um exemplo de treinamento supervisionado, em que a regra de aprendizagem é fornecida com um conjunto de exemplos de comportamento de rede desejado. À medida que cada entrada é aplicada à rede, a saída da rede é comparada ao destino. O erro é calculado como a diferença entre a saída de destino (*target*) e a saída da rede. O algoritmo LMS ajusta os pesos e bias da rede linear de modo a minimizar este erro quadrático médio (DEMUTH; BEALE, 1994). Portanto, o Erro Quadrado Médio (*mse*), será:

$$mse = \frac{1}{N} \sum_{k=1}^{N} e(k)^2 = \frac{1}{N} \sum_{k=1}^{N} (t(k) - a(k))^2$$
(2.7)

Onde:

- e(k) : erro;
- t(k) : Saída de destino (target);
- a(k) : Saída da rede.

Quando aplicado a RNA para previsão de demanda, existem vários modelos de rede que podem ser usados, como *Feed-forward BackPropagation* (FFBP), *Layer recurrent Back Propagation* (LRBP) e assim por diante. A *Backpropagation* (BP) é a arquitetura de RNA mais popular usada (PAN; LEE, 2012).

As redes *feedforward* (FF) frequentemente têm uma ou mais camadas ocultas de neurônios sigmóides seguidas por uma camada de saída de neurônios lineares. As camadas múltiplas de neurônios com funções de transferência não lineares permiti que a rede de aprenda relações lineares e não lineares entre vetores de entrada e de saída. A camada de saída linear permite que a rede produza valores fora do intervalo de -1 a +1 (DEMUTH; BEALE, 1994).

As *Feed Forward Neural Networks* (FFNN) são as redes de mapeamento não-linear com excelentes capacidades de aproximação de função. Os nós de origem na camada de entrada da rede fornecem o vetor de entrada para os neurônios na camada oculta. Os sinais de saída da camada oculta são usados como entradas para a camada de saída. Os sinais de saída dos neurônios na camada de saída constituem a resposta geral da rede. Embora simples de implementar, as FFNNs são dispositivos muito flexíveis nos quais muitos ajustes precisam ser realizados, como seleção de variáveis de entrada, número de neurônios na camada oculta, seleção de dados de treinamento, função de ativação usada em camadas ocultas e de saída, algoritmo de treinamento e meta de desempenho usados, etc (AGGARWAL; KUMAR, 2016).

As redes neurais de BP usam funções continuamente valorizadas e aprendizado supervisionado, ou seja, no aprendizado supervisionado, os pesos numéricos reais atribuídos às entradas do elemento são determinados pela correspondência de dados históricos (como tempo e clima) às saídas desejadas (como cargas elétricas históricas) em uma "sessão de treinamento"pré-operacional (PAN; LEE, 2012).

A *Backpropagation* foi criada generalizando a regra de aprendizagem Widrow-Hoff para redes de camadas múltiplas e funções de transferência diferenciáveis não lineares. Os vetores de entrada e os vetores de destino correspondentes são usados para treinar uma rede até que ela possa se aproximar de uma função, associar os vetores de entrada a vetores de saída específicos ou classificar os vetores de entrada de maneira apropriada.. O termo *Backpropagation* refere-se à maneira como o gradiente é calculado para redes multicamadas não lineares. (DEMUTH; BEALE, 1994).

A aprendizagem por BP consiste basicamente de dois passos: 1) Passo para frente, propagação, os pesos sinápticos da rede são invariáveis e; 2) Passa para trás, retropropagação, os pesos serão ajustados conforma uma regra de correção de erro. Portanto, que a resposta real da rede é subtraída da resposta desejada para produzir um sinal de erro, que será retropropagado por meio da rede, no sentido contrário das conexões sináptica. Os pesos sinápticos são ajustados para que a resposta da rede seja a mais próxima da resposta de objetivo.

2.3.3 Aplicações de Previsão de Demanda com RNA

A aplicação de métodos de RNA para previsão de demanda, é bastante estudada, com isso diversos trabalhos e teses surgem anualmente sobre o tema.

De acordo a pesquisa do autor (MEDEIROS, 2019), a previsão de demanda de energia foi implementada utilizando métodos de RNA considerando a influência de temperatura e potência. Os resultados mostram que apenas a potência teve maior confiabilidade entre a previsão e o objetivo, este resultado pode ser explicado devido a baixa correlação entre temperatura e chuva.

De acordo com os autores (MEDEIROS et al., 2016), a previsão de demanda foi realizada utilizando dois métodos de IA, sendo RNA e Lógica Fuzzy. Para esta previsão foram considerados amostras de potência como entrada de variáveis, de acordo com os resultados apresentados, os dois métodos obtiveram resultados de MAPEs menor que 4%, com isso dando maior confiabilidade da previsão.

3 Previsão de Demanda de Energia

3.1 Objeto de estudo

O objeto de estudo foi uma subestação e os dados de potência ativa foram fornecidos por uma concessionária. Os dados de potência ativa foram extraídos do alimentador 21L1, ilustrado pela Figura 7.



Figura 7 – Diagrama unifilar simplificado de uma subestação

Fonte: Elaborado pela autora, 2020.

Para a previsão de demanda, além de dados de potência ativa, utilizou-se dados de temperatura e chuva que foram obtidos para a cidade de João Pessoa, por meio do site da INMET (Instituto Nacional de Meteorologia) (INMET, 2020). Os dados utilizados para estudo são para os anos de 2011, 2012 e 2013.

Na Figura 8 é apresentado um diagrama para a elaboração da previsão de demanda.



Figura8– Diagrama para a Previsão de demanda

Fonte: Elaborado pela autora, 2020.

3.2 Implementação do Banco de dados

Para a modelagem da previsão de demanda, softwares como Microsoft[®]Excel e MATLAB[®] foram utilizados. Dados de potência fornecidos pela concessionária e dados de

temperatura e chuva extraídos por meio do site da INMET (INMET, 2020).

Para as entradas da rede neural artificial, considerou-se cinco valores de potência, sendo valor atual e valores passados, dois valores de temperatura, sendo valor atual e valores passados, e quatro valores de chuva, sendo valor atual e valores passados.

Na Figura 9 é apresentado um modelo representativo das entradas de variáveis a RNA e sua saída, onde k significa o instante atual, k-1 são valores passados e k+1 são os valores futuros, este último será o resultado da nossa previsão de demanda. Além dos dados de potência, temperatura e chuva, dados de energia também foram introduzidos como uma finalidade de comparar os resultados e verificar a influência da energia em conjunto com os outros dados de entrada.



Figura 9 – Entradas e Saídas da RNA de estudo

Fonte: Elaborado pela autora, 2020.

Sendo,

 $\mathbf{P} = \text{Potência};$

 \mathbf{T} = Temperatura;

 $\mathbf{C} = \mathrm{Chuva}.$

A janela de previsão utilizada foi de cinco combinações sendo: sete valores atrasados (dois de potência e cinco de temperatura), onze valores atrasados (dois de potência, cinco de

temperatura e quatro de chuva), cinco valores atrasados (potência), doze dados atrasados (cinco de potência, dois de temperatura e cinco de energia) e dezesseis valores atrasados (cinco de potência, dois de temperatura, cinco de energia e quatro de chuva) para fornecer um horizonte de dois dias.

Para uma maior eficiência ao resultado das previsões a inclusão de outras variáveis altamente correlacionadas com a demanda devem ser consideradas. Portanto, para este projeto a variável de temperatura, chuva e energia como entrada foram implementadas, juntamente com a implementação da energia, com a finalidade de um melhor resultado na previsão de demanda.

3.2.1 Banco de Dados

Os dados de potência ativa, corrente, tensão etc., são obtidos por meio de um sistema de supervisão e aquisição de dados (SCADA), que é responsável pelo recebimento de dados dos equipamentos/barramentos da subestação e enviados para um banco de dados, ficando acessível para a concessionária. Analisando-se o banco de dados detectou a presença de inconsistências, tais como: picos, espaços em branco, valores nulos, entre outros. Esses tipos de medições são denominadas *outliers* na literatura formal, e podem ser ocasionadas por erros de leitura e falhas no SCADA.

Porém, independentemente da natureza, um *outlier* em uma série temporal deverá ser corrigido para que não haja comprometimento no modelo de previsão, já que a confiabilidade dos dados é indispensáveis para o processo (GUO et al., 2012) e (TAYLOR, 2008).

Como este trabalho não é direcionado para a correção e identificação de outliers, é necessário informar a necessidade do tratamento prévio dos dados. Sendo assim, a premissa básica que as séries temporais passaram pelo processo de correção.

Os dados de potência são obtidos em intervalos de quinze em quinze minutos, totalizando noventa e seis medições por dia, esses dados foram tratados com a utilização do software MATLAB[®], os dados de potência foram compilados em dados de potência máximas diárias e posteriormente em dados de potências máximas semanais para os anos de 2011, 2012 e 2013. Para os dados pluviométricos (chuvas) e de temperatura, foram compilados em valores máximos semanais, para os mesmos anos. Para os dados de energia, foi calculado como sendo o somatório das potências semanais, multiplicados cada potência por um quarto de hora.

Ao final das compilações, o banco de dados foi implementado com dados de potência máxima semanal, temperatura máxima semanal, dados pluviométricos (chuvas) semanais e energia semanal para os anos de 2011, 2012 e 2013. A normalização dos dados é feita automaticamente pelo *software* MATLAB[®].

3.3 Treinamento da RNA

Para o treinamento da RNA , os dados de entrada foram construídos, Na Figura 10 é apresentado um modelo esquemático das entradas. Onde amostras passadas de potência, temperatura e chuva constituem a entrada da RNA para o treinamento, a matriz de valores foi construída conforme descrito na seção 3.2.

Pk P_{k-1} P_{k-2} P_{k+1} P_{k-3} P_{k+2} P_{k-4} P_{k+3} Tĸ RNA P_{k+4} **T**_{k-1} ... T_{k-2} Cĸ C_{k-1} ...

Figura 10 – Modelo da RNA com entradas e saídas

Fonte: Elaborado pela autora, 2020.

As seguintes combinações para as entradas da RNA foram utilizadas, para treinamento da RNA.

- 1) Potência;
- 2) Potência e temperatura;
- 3) Potência, temperatura e chuva;

Como complemento, os dados de energia foram acrescidos na simulação e implementados as combinações 2 e 3, sendo assim, ao final, o total dados de entrada passadas e variáveis utilizadas nas simulações, foram:

- 1) Potência;
- 2) Potência e temperatura;
- 3) Potência, temperatura e energia;
- 4) Potência, temperatura e chuva;

5) Potência, temperatura, chuva e energia.

Para o treinamento da RNA, são utilizados os dados referentes ao ano de 2011 e 2012. Para teste são utilizados os dados referente ao ano de 2013.

3.4 Parâmetros de treinamento da RNA

Com a utilização do software MATLAB[®] para as simulações de RNA, os seguintes parâmetros e configurações foram considerados:

Número de camadas : 2 camadas;

- Número de neurônios : Para o treinamento da rede, iterações de 1 a 40 foram realizadas, totalizando 1600 resultados para cada combinação. Com isso será possível descobrir o número de neurônios para cada camada.
- Algoritmo de aprendizado : Para o desenvolvimento da RNA, utilizou-se o Neural Network Toolbox do MATLAB[®] (versão R2018a). Dois algoritmos, ou função de treinamento de rede, foram utilizados para estudo, sendo o Levenberg-Marquardt backpropagation definido neste software como trainlm e o Gradient descent backpropagation definido neste software como traingd.

O traingd significa uma função de treinamento de rede que atualiza os valores de peso e bias de acordo com a descida do gradiente. O trainlm significa que esta função de treinamento de rede atualiza os valores de peso e bias de acordo com a otimização de Levenberg-Marquardt.

Como parâmetro de treinamento, é utilizado Redes de múltiplas camadas, por meio da função FFBP correspondente ao comando *newff* do MATLAB[®], onde existe mais de uma camada oculta, conforme apresenta na Figura 11. O sinal de entrada irá se propagar pela rede, camada por camada. Essas redes, são normalmente chamadas de MPL.



Figura 11 – Rede MPL com duas camadas ocultas

Fonte: Adaptado do (HAYKIN, 2001).

Para a função de ativação é utilizado a função Tan-Sigmoid (DEMUTH; BEALE, 1994), representado pelo MATLAB[®] por *tansig*. Durante o treinamento da rede, surgir uma janela (*Neutral Network Training*), para cada simulação. Na Figura 12 é apresentado esta janela para dois casos de funções de treinamento de rede (*trainlm* e *traingd*).

Figura 12 – Neural Network Training do MATLAB®

📣 Neural Network Training (nntraintool) 🗕 🗆 🗙	📣 Neural Network Training (nntraintool) 🗕 🗆 🗙		
Neural Network Hidden Layer 1 Hidden Layer 2 Output Layer 5 40 40 40 2	Neural Network Höden Layer 1 Höden Layer 2 Neural Network Höden Layer 2 Neural Network Neural Neural Network Neural Neural N		
Algorithms Data Division: Random (dividerand) Training: Levenberg-Marquardt (trainlm) Performance: Mean Squared Error (mse) Calculations: MEX	Algorithms Data Division: Random (dividerand) Training: Gradient Descent (traingd) Performance: Mean Squared Error (mse) Calculations: MEX		
Progress Epoch: 0 15 iterations 1000 Time: 0.0011 0.00 0.00 Performance: 6.29 0.00494 0.00 Gradient: 23.6 0.0159 1.00e-07 Mu: 0.00100 0.00100 1.00e+10 Validation Checks: 0 6 6	Progress 0 872 iterations 1000 Time: 0:00:02 0 0 Performance: 0.311 0.145 0.00 Gradient: 0.670 0.0382 1.00e-05 Validation Checks: 0 0 6		
Plots Performance (plotperform) Training State (plotrainstate) Regression (plotregression) Plot Interval: Quantum programming and any and any and any and any and any and any	Plots Performance (plotperform) Training State (plottrainstate) Regression (plotregression) Plot Interval:		
Validation stop.	Training neural network		

Fonte: Elaborado pela autora, 2020.

A partir das imagens da Figura 12, é possível observar o número de entradas simuladas para determinado caso, as camadas ocultas e os determinados neurônios de cada

camada e o número de dados de saída. O tipo de função de treinamento de rede também pode ser observado para cada caso.

A função de desempenho padrão para redes feedforward é o erro quadrático médio (mse) - o erro quadrático médio entre as saídas da rede a e as saídas target t.

3.5 Teste e validação da RNA

Para o treinamento da RNA, é implementado ao código um algoritmo para a obter o MAPE e ERRO relativo de cada RNA. Com isso, foi possível verificar qual combinação de camadas obtiveram menos valores de MAPE e ERRO relativo.

Para o cálculo do ERRO relativo, é utilizado a seguinte expressão:

$$ERRO = \left|\frac{P_j - T_j}{P_j}\right| * 100 \tag{3.1}$$

Onde,

- P_j : previsão (simulação dos dados), para j= 1,2,3, ..., N;
- T_j : teste (banco de dados), para j= 1,2,3, ..., N;

O MAPE (*Mean Absolute Percentage Error*) corresponde à média do erro absoluto relativo. É uma técnica bastante utilizada na avaliação de acurácia em métodos de previsão estatística. Matematicamente, o MAPE é definido conforme equação 3.2:

$$MAPE = \frac{1}{N} * \sum_{j=1}^{N} \left| \frac{P_j - T_j}{P_j} \right| * 100$$
(3.2)

Onde,

- N: tamanho do conjunto de validação;
- P_j : previsão (simulação dos dados), para j= 1,2,3, ..., N;
- T_j : teste (banco de dados), para j= 1,2,3, ..., N;

A MAPE mede a precisão da previsão comparando o erro percentual nos valores reais e previstos (DEHALWARA et al., 2016).

A seleção do melhor modelo de RNA foi determinado pela menor MAPE (MAKRI-DAKIS; WHEELWRIGHT; HYNDMAN, 1998). A validação está interligada a simulação da rede para o conjunto de dados que não foram aplicados no treinamento. A cada passo, o valor previsto será realimentado para o grupo de entradas, de forma que os valores a serem previstos sofram influência da previsão anterior. A partir da Figura 13, é possível visualizar um exemplo da forma como as entradas e saídas se comportam no processo de validação, onde os valores previstos (P4', P5', P6', T4', T5', T6'...) são transferidos para as entradas seguintes, substituindo os valores reais (P4, P5, P6, T4, T5, T6...).





Fonte: Elaborado pela autora, 2020.

3.6 Cálculo da Correlação

Para o cálculo da correlação foi utilizado o comando *correcef* do *software* MATLAB[®], onde foi implementada ao código e determinado os termos da correlações.

Para o banco de dados de potência máxima semanal, temperatura máxima semanal, dados pluviométricos (chuvas) semanais e energia semanal para os anos de 2011, 2012 e 2013, é realizado a correlação entre as variáveis de potência máxima semanal e temperatura máxima semanal, potência máxima semanal e dados pluviométricos (chuvas), é potência máxima semanal e energia semanal, para os anos de 2011, 2012. Com a compilação do código, uma matriz será exibida e apresentará os coeficientes de correlação (ρ). A correlação entre vetores iguais será igual a 1.

• Correlação entre Potência e Temperatura, onde P e T representam os vetores dos valores de potência e temperatura, respectivamente, teremos:

$$\left(\begin{array}{cc}\rho(P,P) & \rho(P,T)\\\rho(T,P) & \rho(T,T)\end{array}\right)$$

Como resultado, a matriz a seguir é exibida:

$$\left(\begin{array}{cc} 1.0000 & 0.7635\\ 0.7635 & 1.0000 \end{array}\right)$$

• Correlação entre Potência e Chuva, onde P e C representam os vetores dos valores de potência e chuva, respectivamente, teremos:

$$\left(\begin{array}{cc}\rho(P,P) & \rho(P,C)\\\rho(C,P) & \rho(C,C)\end{array}\right)$$

Como resultado, a matriz a seguir é exibida:

$$\left(\begin{array}{rrr} 1.0000 & -0.2345 \\ -0.2345 & 1.0000 \end{array}\right)$$

• Correlação entre Potência e Energia, onde P e E representam os vetores dos valores de potência e energia, respectivamente, teremos:

$$\left(\begin{array}{cc}\rho(P,P) & \rho(P,E)\\\rho(E,P) & \rho(E,E)\end{array}\right)$$

Como resultado, a matriz a seguir é exibida:

$$\left(\begin{array}{cc} 1.0000 & 0.9368\\ 0.9368 & 1.0000 \end{array}\right)$$

Correlação ou dependência, é uma relação estatística entre duas variáveis, ou seja, apresenta a relação entre as variáveis de estudo. O método de correlação do MATLAB[®] consiste em *Pearson correlation coefficient*, do qual para a matriz de correlação, os coeficientes de correlação são simbolizado pela letra grega ρ .

Para coeficientes que estão mais próximos do termo +1, significará uma relação linear positiva, para o caso em que o coeficiente esteja próximo de -1, significará em uma correlação negativa ou inversa.

O valor de ρ está no intervalo [-1, 1]. E quanto maior o valor, maior será a taxa de correlação linear entre as duas variáveis. Quando $\rho = 1$, as duas variáveis são uma correlação completamente positiva. Quando $\rho = -1$, as duas variáveis são uma correlação completamente negativa. Quando $\rho = 0$, a correlação linear entre as duas variáveis não é óbvia (XU; DENG, 2017).

De acordo com (MUKAKA, 2012), para um valor positivo de correlação, considerase baixa a correlação no intervalo de 0 a 0,5.

Portanto, quando mais próximo de +1, mais correlacionadas as variáveis estão. De acordo com o resultados, o coeficiente de correlação entre potência e temperatura e entre potência e energia, demonstraram uma maior grau de influência na demanda, pois seus resultados são próximos de +1.

4 Resultados

4.1 Análise dos Resultados

Traingd

Para encontrar a melhor RNA, as redes foram treinadas utilizando duas camadas ocultas, onde cada uma poderia comportar no máximo 40 neurônios. Portanto, foram obtidas 1600 redes no total. É aplicado ao código a função *min* para encontrar qual RNA detém de menor valor de MAPE e menor ERRO relativo e os respectivos números de neurônios de cada camada. Após realizado o treinamento de todas as redes, essas foram avaliadas utilizando os dados de teste (objetivo), considerando um período de 52 semanas.

4.2 Redes com Potência como entrada

Na Tabela 1 são apresentados os resultados para menor MAPE de cada função de treinamento e seus respectivos números de neurônios de cada camada. Na Tabela 2 são apresentadas os resultados para menor ERRO relativo de cada função de treinamento e seus respectivos números de neurônios de cada camada.

	L		
Função do Troinamonto	RNA		Monor MADE [02
Função de Tremamento	Camada 1	Camada 2	
Trainlm	2	7	3.1903

32

Tabela 1 – Resultado para menor MAPE com Traingd e Trainlm

Fonte: Elaborado pela autora, 2020.

8

3.0352

Tabela 2 – Resultado para menor ERRO com Traingd e Trainlm

Função do Troinamonto	RNA		Monor FRRO [%]
Função de Tremamento	Camada 1	Camada 2	
Trainlm	11	23	10.2557
Traingd	3	27	9.6776

Fonte: Elaborado pela autora, 2020.

Na Figura 14 é apresentado as curvas de saídas para menor MAPE para os dois casos de funções de treinamento utilizadas, *trainlm* e *traingd*, e a curva objetivo.



Figura 14 – Curvas de saída para menor MAPE com TraingdeTrainlm

Fonte: Elaborado pela autora, 2020.

Na Figura 15 são apresentadas as curvas de saída para os dois casos das funções de treinamento e a curva objetivo, quando considerado o menor erro relativo.

Figura 15 – Curvas de saída para menor ERRO relativo com Traingd e Trainlm



Fonte: Elaborado pela autora, 2020.

Nas Figuras 16 e 17 são ilustrados o comportamento do MAPE para todas as redes

treinadas com a função de treinamento trainlm e traingd, respectivamente, é destacados os valores mínimos destas variáveis.



Figura 16 – Comportamento do MAPE para Trainlm

Fonte: Elaborado pela autora, 2020.

Figura 17 – Comportamento do MAPE para Traingd



Fonte: Elaborado pela autora, 2020.

4.3 Redes com Potência e Temperatura como entradas

Na Tabela 3 são apresentados os resultados para menor MAPE de cada função de treinamento e seus respectivos números de neurônios de cada camada. Na Tabela 4 são apresentados os resultados para menor ERRO relativo de cada função de treinamento e seus respectivos números de neurônios de cada camada.

Função do Troinamonto	RNA		Monor MAPE [%]
Função de Tremamento	Camada 1	Camada 2	
Trainlm	25	17	2.9782
Traingd	10	10	3.2845

Tabela 3 – Resultado para menor MAPE com Traingd e Trainlm

Fonte: Elaborado pela autora, 2020.

Tabela 4 – Resultado para menor ERRO com Traingd e Trainlm

Função do Troinamonto	\mathbf{RNA}		Monor FRRO [%]
Função de Tremamento	Camada 1	Camada 2	
Trainlm	5	12	10.3467
Traingd	23	1	9.8934

Fonte: Elaborado pela autora, 2020.

Na Figura 18 são apresentadas as curvas de saídas para menor MAPE para os dois casos de funções de treinamento utilizadas, *trainlm* e *traingd*, e a curva objetivo.

Figura 18 – Curvas de saída para menor MAPE com TraingdeTrainlm



Fonte: Elaborado pela autora, 2020.

Na Figura 19 são apresentadas as curvas de saída para os dois casos das funções de treinamento e a curva objetivo, quando considerado o menor erro relativo.



Figura 19 – Curvas de saída para menor ERRO com TraingdeTrainlm

Fonte: Elaborado pela autora, 2020.

Nas Figuras 20 e 21 são ilustrados o comportamento do MAPE para todas as redes treinadas com a função de treinamento *trainlm* e *traingd*, respectivamente, é destacados os valores mínimos destas variáveis.



Figura 20 – Comportamento do MAPE para Trainlm

Fonte: Elaborado pela autora, 2020.



Figura 21 – Comportamento do MAPE para Traingd

Fonte: Elaborado pela autora, 2020.

4.4 Redes com Potência, Temperatura e Energia como entradas

Na Tabela 5 são apresentados os resultados para menor MAPE de cada função de treinamento e seus respectivos números de neurônios de cada camada. Na Tabela 6 são apresentados os resultados para menor ERRO relativo de cada função de treinamento e seus respectivos números de neurônios de cada camada.

Função do Troinamonto	RNA		Monor MADE [%]
Função de Tremamento	Camada 1	Camada 2	
Trainlm	27	1	2.8713
Traingd	15	19	3.0203

Tabela 5 – Resultado para menor MAPE com Traingd e Trainlm

Fonte: Elaborado pela autora, 2020.

Tabela 6 – Resultado para menor ERRO com Traingd e Trainlm

Função do Troinamonto	RNA		Monor FRRO [%]
Função de Tremamento	Camada 1	Camada 2	
Trainlm	18	13	9.4810
Traingd	40	15	8.8714

Fonte: Elaborado pela autora, 2020.

Na Figura 22 são apresentadas as curvas de saídas para menor MAPE para os dois casos de funções de treinamento utilizadas, *trainlm* e *traingd*, e a curva objetivo.



Figura 22 – Curvas de saída para menor MAPE com TraingdeTrainlm

Fonte: Elaborado pela autora, 2020.

Na Figura 23 são apresentadas as curvas de saída para os dois casos das funções de treinamento e a curva objetivo, quando considerado o menor erro relativo.



Figura 23 – Curvas de saída para menor ERRO com TraingdeTrainlm

Fonte: Elaborado pela autora, 2020.

Nas Figuras 24 e 25 são ilustrados o comportamento do MAPE para todas as redes treinadas com a função de treinamento trainlm e traingd, respectivamente, é destacados os valores mínimos destas variáveis.



Figura 24 – Comportamento do MAPE para Trainlm

Fonte: Elaborado pela autora, 2020.





Fonte: Elaborado pela autora, 2020.

4.5 Redes com Potência, Temperatura e Chuva como entradas

Na Tabela 7 são apresentados os resultados para menor MAPE de cada função de treinamento e seus respectivos números de neurônios de cada camada. Na Tabela 8 são apresentados os resultados para menor ERRO relativo de cada função de treinamento e seus respectivos números de neurônios de cada camada.

Função do Troinamonto	RNA		Monor MAPE [%]
Função de Tremamento	Camada 1	Camada 2	
Trainlm	14	19	3.2179
Traingd	37	15	3.4475

Tabela 7 – Resultado para menor MAPE com Traingd e Trainlm

Fonte: Elaborado pela autora, 2020.

Tabela 8 – Resultado para menor ERRO com Traingd e Trainlm

Função de Treinamento	RN	NA	Monor FRBO [%]	
	Camada 1	Camada 2		
Trainlm	38	3	10.2043	
Traingd	30	7	10.4596	

Fonte: Elaborado pela autora, 2020.

Na Figura 26 são apresentadas as curvas de saídas da menor MAPE para os dois casos de funções de treinamento utilizadas, *trainlm* e *traingd*, e a curva objetivo.





Fonte: Elaborado pela autora, 2020.

Na Figura 27 são apresentadas as curvas de saída para os dois casos das funções de treinamento e a curva objetivo, quando considerado o menor erro relativo.



Figura 27 – Curvas de saída para menor ERRO com TraingdeTrainlm

Fonte: Elaborado pela autora, 2020.

Nas Figuras 28 e 29 são ilustrados o comportamento do MAPE para todas as redes treinadas com a função de treinamento *trainlm* e *traingd*, respectivamente, é destacados os valores mínimos destas variáveis.



Figura 28 – Comportamento do MAPE para Trainlm

Fonte: Elaborado pela autora, 2020.



Figura 29 – Comportamento do MAPE para Traingd

Fonte: Elaborado pela autora, 2020.

4.6 Redes com Potência, Temperatura, Chuva e Energia como entradas

Na Tabela 9 são apresentados os resultados para menor MAPE de cada função de treinamento e seus respectivos números de neurônios de cada camada. Na Tabela 10 são apresentados os resultados para menor ERRO relativo de cada função de treinamento e seus respectivos números de neurônios de cada camada.

Função de Treinamento	RN	NA	Monor MADE [07]	
	Camada 1	Camada 2		
Trainlm	27	8	3.1867	
Traingd	26	18	3.1204	

Tabela 9 – Resultado para menor MAPE com Traingd e Trainlm

Fonte: Elaborado pela autora, 2020.

Fabela 10 –	Resultado	para menor	ERRO con	m <i>Traingd</i> e	Trainlm
-------------	-----------	------------	----------	--------------------	---------

Função de Treinamento	RI	NA	Monor FDDO [%]	
	Camada 1	Camada 2	Menor Entro [70]	
Trainlm	16	11	9.5822	
Traingd	39	8	8.9906	

Fonte: Elaborado pela autora, 2020.

Na Figura 30 são apresentadas as curvas de saídas da menor MAPE para os dois casos de funções de treinamento utilizadas, *trainlm* e *traingd*, e a curva objetivo.



Figura 30 – Curvas de saída para menor MAPE com TraingdeTrainlm

Fonte: Elaborado pela autora, 2020.

Na Figura 15 são apresentadas as curvas de saída para os dois casos das funções de treinamento e a curva objetivo, quando considerado o menor erro relativo.





Fonte: Elaborado pela autora, 2020.

Nas Figuras 32 e 33 são ilustrados o comportamento do MAPE para todas as redes treinadas com a função de treinamento trainlm e traingd, respectivamente, é destacados os valores mínimos destas variáveis.





Fonte: Elaborado pela autora, 2020.



Figura 33 – Comportamento do MAPE para Traingd

Fonte: Elaborado pela autora, 2020.

4.7 Discussão sobre os resultados

Comparando os resultados apresentados nas Tabelas 1, 3, 5, 7 e 9, referentes aos resultados das menores MAPEs, a RNA com entradas em potência, temperatura e energia resultou em um menor valor MAPE.

Na Tabela 11 são apresentados novamente os valores resultantes das menores MAPEs para cada função de treinamento e os respectivos números de neurônios de cada camada. Na Figura 34 são apresentadas as curvas de saída para estes resultados citados anteriormente, para ambos os casos de funções de treinamento.

Funções de Treinamento	RN	NA	Monor MADE [%]	
	Camada 1	Camada 2		
Trainlm	27	1	2.8713	
Traingd	15	19	3.0203	

Tabela 11 – Resultado final das RNAs

Fonte:	Elaborado	pela	autora,	2020.
--------	-----------	------	---------	-------



Figura 34 – Curvas de saídas das melhores RNAs

Fonte: Elaborado pela autora, 2020.

Estes resultados podem ser explicados devido ao valor da correlação entre potência e temperatura de $\rho(P,T) = 0.7635$ e entre potência e energia de $\rho(P,E)$ = 0.9368.

As condições climáticas têm impactos significativos na carga prevista, especialmente em curto e médio prazo (NAHID-AL-MASOOD et al., 2010).

O clima é um parâmetro importante, que define a condição dos elementos meteorológicos, como temperatura, umidade, vento, chuva, etc., e como eles variam em uma região durante um determinado período de tempo (LEKSHMI; SUBRAMANYA, 2019).

Para o caso da variável chuva, os resultados das simulações podem ser justificados devido a correlação negativa entre potência e chuva.

A precipitação (chuva) pode afetar diretamente e indiretamente o consumo de carga (FAHAD; ARBAB, 2014). A depender da região, com fortes chuvas aumenta-se o uso de aquecedoras, com isso aumento de consumo de energia, contudo em outras regiões, o aumento de chuvas resulta da diminuição do uso de equipamentos de refrigeração, com isso, ocorre uma diminuição do consumo de energia.

5 Conclusões

Este trabalho apresentada uma metodologia de previsão de demanda de energia para uma subestação. O objetivo foi implementar um algoritmo com a utilização do software MATLAB[®] com a finalidade de previsão de demanda como entradas combinações de potência, temperatura, chuva e energia, a fim de encontrar qual apresenta a curva mais próxima ao desejado.

Diante do que foi apresentado, foram utilizadas metodologias de Redes Neurais Artificiais, que constituem por técnicas computacionais de inteligência artificial. Com os dados de potência passados, fornecidos pela concessionária de energia, e valores de temperatura da mesma região, obtidos pelo site do Instituto Nacional de Meteorologia (INMET), ambos para o ano de 2011, 2012 e 2013, as redes foram devidamente treinadas.

Analisando os resultados, a inclusão dos valores de temperatura e energia como entradas contribuíram para um bom resultado para este estudo de caso, pois conforme descrito na seção 3.6, a correlação entre potência com temperatura e potência com energia foram próximo de 1, para as duas funções de treinamento (*trainlm* e *traingd*) implementadas. Ao compararmos as menores MAPEs para cada função de treinamento, são obtidos para a função de treinamento *trainlm* um valor de menor MAPE de 2.8713% e para a função de treinamento de rede *traingd* um valor de menor MAPE de 3.0203%, comparando-se estes dois últimos resultados, com a função de treinamento *trainlm* iremos obter uma menor MAPE de todos os resultados compilados.

As atividades realizadas foram estruturadas através da construção de um banco de dados envolvendo informações passadas de potência, temperatura, chuva e energia, correlação das variáveis, e treinamento baseado em Redes Neurais Artificiais do tipo MultiLayer Perceptron. Para o banco de dados, foram extraídos os valores semanais de potência, temperatura, chuva e energia. A correlação das variáveis contou como objetivo de determinar o nível de dependência existente entre os dados de potência e temperatura, potência e chuva, e potência e energia. O treinamento foi desde a elaboração da metodologia de previsão, estabelecimento de parâmetros, definição do algoritmo, até a fase de testes para, por fim, gerar os resultados finais.

Portanto, com as métricas aplicadas para verificar o desempenho dos resultados das topologias e combinações de RNA estudadas, obtive-se resultados satisfatórias.

Referências

AGGARWAL, S. K.; KUMAR, M. Ann based residential demand forecasting using weather and special day information. In: 2016 7th India International Conference on Power Electronics (IICPE). [S.l.: s.n.], 2016. p. 1–5.

ANEEL. Como funciona o setor elétrico brasileiro? 2020. Disponível em: <https://www.aneel.gov.br/home?p_p_id=101&p_p_lifecycle=0&p_p_state= maximized&p_p_mode=view&_101_struts_action=%2Fasset_publisher%2Fview_ content&_101_returnToFullPageURL=%2F&_101_assetEntryId=14476909&_101_ type=content&_101_groupId=654800&_101_urlTitle=faq&inheritRedirect=true>. Acesso em 07 de novembro de 2020.

AQUINO, R. R. B. de et al. A hybrid intelligent system for short and mid-term forecasting for the celpe distribution utility. In: *The 2006 IEEE International Joint Conference on Neural Network Proceedings.* [S.l.: s.n.], 2006. p. 2656–2661.

AYOUB, N. et al. Ann model for energy demand and supply forecasting in a hybrid energy supply system. In: 2018 IEEE International Conference on Smart Energy Grid Engineering (SEGE). [S.l.: s.n.], 2018. p. 25–30.

BOX, G. E. P. et al. *Time series analysis : forecasting and control.* 5. ed. [S.l.]: Wiley, 2016. ISBN 978-1-118-67502-1.

BRACE, M. C.; SCHMIDT, J.; HADLIN, M. Comparison of the forecasting accuracy of neural networks with other established techniques. In: *Proceedings of the First International Forum on Applications of Neural Networks to Power Systems*. [S.l.: s.n.], 1991. p. 31–35.

CARMONA, D. et al. Electric energy demand forecasting with neural networks. IECON, 2002.

DEHALWARA, V. et al. Electricity load forecasting for urban area using weather forecast information. IEEE International Conference on Power and Renewable Energy, 2016.

DEMUTH, H.; BEALE, M. Neural network toolbox: For use with matlab. The Math Works, 1994.

ELETROBRAS. *Mapas do Sistema Elétrico Brasileiro*. 2020. Disponível em: <https://eletrobras.com/pt/Paginas/Sistema-Eletrico-Brasileiro.aspx>. Acesso em 07 de novembro de 2020.

ELGARHY, S. M. et al. Short term load forecasting using ann technique. In: 2017 Nineteenth International Middle East Power Systems Conference (MEPCON). [S.l.: s.n.], 2017. p. 1385–1394.

EPE. Sistemas Isolados. 2020. Disponível em: https://www.epe.gov.br/pt/ publicacoes-dados-abertos/publicacoes/sistemas-isolados>. Acesso em 25 de Novembro de 2020.

EPE. SISTEMAS ISOLADOS: Planejamento do Atendimento aos Sistemas Isolados. 2020. Disponível em: <a href="https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/Publicacoes

FAHAD, M. U.; ARBAB, N. Factor affecting short term load forecasting. Journal of Clean Energy Technologies, v. 2, n. 4, 2014.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. Brasília, v. 35, n. 1, p. 25–30, 2006.

FILIPPOV, S. P.; GRYGORIEVA, N. A.; MAKAROVA, E. M. Energy demand forecasting system. In: 2018 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon). [S.l.: s.n.], 2018. p. 1–7.

FURTADO, M. I. V. *Redes neurais artificiais [recurso eletrônico] : uma abordagem para sala de aula.* Ponta Grossa (PR): Atena Editora, 2019.

GAO, M.; FENG, Q.; TIAN, J. Research and application of urban logistics demand forecast based on radial basic function neural network. First International Workshop on Education Technology and Computer Science, 2009.

GHIASSI, M.; ZIMBRA, D.; SAIDANE, H. Medium term system load forecasting with a dynamic artificial neural network model. Electric Power Systems Research, v. 76, n. 5, p. 302–316, 2006.

GUO, Z. et al. Detecting x-outliers in load curve data in power systems. *IEEE Transactions on Power Systems*, v. 27, n. 2, p. 875–884, 2012.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, v. 5, n. 6, p. 989–993, 1994.

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

HONG, Z. A preliminary study on artificial neural network. In: 2011 6th IEEE Joint International Information Technology and Artificial Intelligence Conference. [S.l.: s.n.], 2011. v. 2, p. 336–338.

INMET. Instituto Nacional de Meteorologia. 2020. Disponível em: br/>. Acesso em 25 de Novembro de 2020">https://portal.inmet.gov.br/>br/>. Acesso em 25 de Novembro de 2020.

JACOBS, W.; SOUZA, A. M.; ZANIN, R. R. Combination of box-jenkins and mlp/rna models for forecasting. *IEEE Latin America Transactions*, v. 14, n. 4, p. 1870–1878, 2016.

KAFAZI, I. E.; BANNARI, R.; ABOUABDELLAH, A. Modeling and forecasting energy demand. In: 2016 International Renewable and Sustainable Energy Conference (IRSEC). [S.l.: s.n.], 2016. p. 746–750.

KAGAN, N.; OLIVER, C. C. B. de; ROBBA, E. J. Introdução aos sistemas de distribuição de energia elétrica. 1. ed. São Paulo: Blucher, 2005. 1-20 p. ISBN 85-212-0355-1.

KARAMPELAS, P. et al. Design of artificial neural network models for the prediction of the hellenic energy consumption. In: 10th Symposium on Neural Network Applications in Electrical Engineering. [S.l.: s.n.], 2010. p. 41–44.

KARAYIANNIS, N.; BALASUBRAMANIAN, M.; MALKI, H. Evaluation of cosine radial basis function neural networks on electric power load forecasting. IEEE, 2003.

KUMAR, S.; MISHRA, S.; GUPTA, S. Short term load forecasting using ann and multiple linear regression. Second International Conference on Computational Intelligence & Communication Technology, 2016.

LEKSHMI, M.; SUBRAMANYA, K. N. A. Short-term load forecasting of 400kv grid substation using r-tool and study of influence of ambient temperature on the forecasted load. Second International Conference on Advanced Computational and Communication Paradigms (ICACCP), 2019.

MACRINI, J. L. R. Modelo de previsão de carga utilizando redes neurais: otimização camada a camada. 2000. Disponível em: https://www.maxwell.vrac.puc-rio.br/colecao. php?strSecao=resultado&nrSeq=7251@1&meta=1>. Acesso em 01 de dezembro de 2020.

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. Forecasting Methods and Applications. 3. ed. New York: John Wiley & Sons, 1998.

MAO, H. et al. Short-term and midterm load forecasting using a bilevel optimization model. IEEE Transactions on Power Systems, v. 24, n. 2, p. 1080 – 1090, 2009.

MEDEIROS, I. E. A. de. Aplicação de redes neurais artificiais para a previsão de demanda em subestações de distribuição considerando a influência da temperatura. 2019. TCC (Bacharel em Engenharia Elétrica), Universidade Federal da Paraíba.

MEDEIROS, R. Álamo O. D. Previsão De Demanda No Médio Prazo Utilizando Redes Neurais Artificiais Em Sistemas De Distribuição De Energia Elétrica. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal da Paraíba, João Pessoa, 2016.

MEDEIROS, R. Álamo Oliveira de et al. Revisão de demanda a médio prazo aplicada em dados reais do sistema de distribuição: uma comparação entre rna e lógica fuzzy. Revista Principia, n. 31, 2016.

MEN, H. et al. Applies of neural networks to identify gases based on electronic nose. In: 2007 IEEE International Conference on Control and Automation. [S.l.: s.n.], 2007. p. 2699–2704.

MORAES, L. A. et al. A fuzzy methodology to improve time series forecast of power demand in distribution systems. IEEE Power & Energy Society General Meeting, 2013.

MUKAKA, M. Statistics corner: A guide to appropriate use of correlation coefficient in medical research. *Malawi medical journal : the journal of Medical Association of Malawi*, v. 24, p. 69–71, 09 2012.

NAHID-AL-MASOOD et al. Temperature sensitivity forecasting of electrical load. The 4th International Power Engineering and Optimization Conf. (PEOCO2010), 2010.

ONS. *SOBRE O SIN: MAPA DINÂMICO DO SIN.* 2020. Disponível em: <http://www.ons.org.br/paginas/sobre-o-sin/mapas>. Acesso em 25 de Novembro de 2020.

PAN, X.; LEE, B. A comparison of support vector machines and artificial neural networks for mid-term load forecasting. 2012.

PANKRATZ, A. Forecasting with univariate box-jenkins models: Concepts and cases. p. 553–555, 05 2008.

PERÇUKU, A.; MINKOVSKAB, D.; STOYANOVAC, L. Big data and time series use in short term load forecasting in power transmission system. The 9th International Conference on Emerging Ubiquitous Systems and Pervasive Networks (EUSPN 2018), 2018.

RAMASUBRAMANIAN, V. *Times Series Analysis.* 2007. Disponível em: <http://apps.iasri.res.in/ebook/EBADAT/5-Modeling%20and%20Forecasting%20Techniques% 20in%20Agriculture/2-time_series_analysis_22-02-07_revised.pdf>. Acesso em 02 de dezembro de 2020.

RIBEIRO, P. M. et al. Sistema computacional para previsão de demanda por energia em pontos de suprimento e subestações da coelba. XVII Seminário Nacional de Distribuição de Energia Elétrica–SENDI. Belo Horizonte, 2006.

RUAS, G. I. S. et al. *Previsão de Demanda de Energia Elétrica Utilizando Redes Neurais Artificiais e Support Vector Regression*. 2020. Disponível em: https://www.cos.ufrj.br/~ines/enia07_html/pdf/27927.pdf). Acesso em 01 de dezembro de 2020.

RUSLAN, F. A.; SAMAD, A. M.; ADNAN, R. 4 hours nnarx flood prediction model using "traingd" and "trainoss" training function: A comparative study. In: 2018 IEEE 14th International Colloquium on Signal Processing Its Applications (CSPA). [S.l.: s.n.], 2018. p. 77–81.

SANTOS, A. H. M.; HADDAD, J.; CRUZ, R. A. P. da. Planejamento da expansão da distribuição: Considerações técnicas e regulatórias. VI CBPE, 2008.

SINGH, A.; SAHAY, K. B. Short-term demand forecasting by using ann algorithms. IEECON, 2018.

TAYLOR, J. W. An evaluation of methods for very short-term load forecasting using minute-by-minute british data. *International Journal of Forecasting*, v. 24, n. 4, p. 645 – 658, 2008. ISSN 0169-2070. Energy Forecasting.

XU, H.; DENG, Y. Dependent evidence combination based on shearman coefficient and pearson coefficient. IEEE, 2017.

YAFFEE, R.; MCGEE, M. Introduction to time series analysis and forecasting: With applications of sas and spss. *With Applications of SASt and SPSSt*, 01 2000.

YING, Z.; HANBIN, X. Study on the model of demand forecasting based on artificial neural network. In: 2010 Ninth International Symposium on Distributed Computing and Applications to Business, Engineering and Science. [S.l.: s.n.], 2010. p. 382–386.