

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

FILIPHE OLIVEIRA LOUBACK

**PREVISÃO DOS INDICADORES DE CONTINUIDADE DEC E FEC
USANDO REDES NEURAIS ARTIFICIAIS**

VITÓRIA
2018

FILIPHE OLIVEIRA LOUBACK

**PREVISÃO DOS INDICADORES DE CONTINUIDADE DEC E FEC
USANDO REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica – PPGEE, do Centro Tecnológico da Universidade Federal do Espírito Santo - UFES, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Domingos Sávio Lyrio Simonetti

Coorientador: Prof. Dr. Oureste Elias Batista.

VITÓRIA
2018

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Tecnológica,
Universidade Federal do Espírito Santo, ES, Brasil)

C886p Louback, Filipe Oliveira, 1992-
Previsão dos indicadores de continuidade DEC e FEC
usando redes neurais artificiais/ Filipe Oliveira Louback. –
2018.
83 f. : il.

Orientador: Domingos Savio Lyrio Simonetti.
Coorientador: Oureste Elias Batista.
Dissertação (Mestrado em Engenharia Elétrica) –
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Qualidade do Sistema. 2. Indicadores de Qualidade. 3.
Redes Neurais Artificiais. 4. Estimação de Indicadores de
Continuidade. I. Simonetti, Domingos Sávio Lyrio. II. Batista,
Oureste Elias. III. Universidade Federal do Espírito Santo.
Centro Tecnológico. IV. Título.

CDU: 621.3

FILIPHE OLIVEIRA LOUBACK

**PREVISÃO DOS INDICADORES DE CONTINUIDADE DEC E FEC
USANDO REDES NEURAIAS ARTIFICIAIS**

Dissertação submetida ao programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 28 de setembro de 2018.

BANCA EXAMINADORA

Prof. Dr. Domingos Sávio Lyrio Simonetti - Orientador
Universidade Federal do Espírito Santo - UFES

Prof. Dr. Oureste Elias Batista - Coorientador
Universidade Federal do Espírito Santo - UFES

Prof. Dr. Patrick Marques Ciarelli – Membro Interno
Universidade Federal do Espírito Santo - UFES

Prof. Dra. Carla César Martins Cunha – Membro Externo PPGEE
Universidade Federal do Espírito Santo - UFES

“Mar calmo nunca fez bom marinheiro.”
(Autor desconhecido)

À minha esposa

Agradecimentos

Meus agradecimentos,

À Deus por ter me dado a permissão de chegar até aqui e por toda a força concedida na concretização deste trabalho.

Aos meus pais, Eliane de Oliveira Louback e Lenival Freitas Louback, responsáveis pela minha educação, que sempre me incentivaram e que nunca mediram esforços para que eu chegasse até essa etapa.

À minha esposa, Késia Alves Coelho Louback, pelo amor, carinho, apoio nos momentos difíceis e por estar sempre ao meu lado.

A EDP Espírito Santo, por permitir e incentivar o desenvolvimento deste trabalho.

Ao professor Dr. Klaus Fabian Coco pelo acompanhamento, ideias, disponibilidade em me ajudar e compartilhar comigo seu conhecimento.

Aos meus orientadores, Professor Dr. Domingos Savio Lyrio Simonetti e Professor Dr. Oureste Elias Batista pela orientação.

Aos demais professores e colegas do LEPAC por terem contribuído de alguma forma na minha jornada.

Aos professores da banca avaliadora Dr. Patrick Marques Ciarelli e Dra. Carla César Martins Cunha.

Resumo

No Brasil, uma das óticas através da qual o desempenho das distribuidoras de energia elétrica é avaliado é a Qualidade do Serviço, que regula a continuidade do fornecimento de energia elétrica através dos indicadores DEC e FEC, estando a distribuidora de energia sujeita a penalidades no caso de não cumprimento dos limites regulatórios. A estimação destes indicadores proporciona um conhecimento do panorama futuro da empresa, oportunizando a identificação de áreas que possuem tendência de piora no tempo. O presente trabalho consiste no desenvolvimento de uma metodologia de estimação dos indicadores de continuidade do fornecimento de energia utilizando a aplicação de Redes Neurais Artificiais. Utilizou-se dados reais da EDP Espírito Santo e objetiva a estimação dos indicadores DEC e FEC diários do conjunto elétrico São Mateus. Os resultados obtidos para a estimação do DEC e do FEC mostram que o modelo proposto é viável. Os erros absolutos acumulados na previsão do indicador DEC ao final dos meses de janeiro e de fevereiro de 2016 foram 1,71% e 0,87%, respectivamente. Na previsão do FEC, os erros absolutos acumulados ao final dos meses de janeiro e de fevereiro de 2016 foram 7,45% e 10,96%, respectivamente. Portanto, os resultados obtidos permitem que decisões mais adequadas sejam tomadas sobre a execução de ações de manutenção e alocação de recursos, contribuindo para a confiabilidade operacional do sistema elétrico.

Palavras-chave: Qualidade do Sistema, Indicadores de Qualidade, Redes Neurais Artificiais, Estimação de indicadores de continuidade.

Abstract

In Brazil, one of the optics through which the energy distributors' performance is evaluated is Quality of Service, which regulates the continuity of electric power supply through the DEC and FEC indicators. The power distributor is subject to penalties in the event of no compliance with regulatory limits. The estimation of these indicators provides a knowledge of the future panorama of the company, allowing the identification of areas that tend to deteriorate over time. The present work consists in the development of a methodology to estimate the indicators of continuity of energy supply using the application of Artificial Neural Networks. The work uses real data from EDP Espírito Santo and aims to estimate the daily DEC and FEC indicators of the São Mateus electrical set. The results obtained from the estimation of DEC and FEC show that the proposed model is feasible. The total errors accumulated in the DEC indicator forecast at the end of January and February 2016 were 1.71% and 0.87%, respectively. In the FEC forecast, the total errors accumulated at the end of January and February 2016 were 7.4468% and 10.9589%, respectively. Therefore, the results obtained by this work allow more adequate decisions are made on the execution of maintenance actions contributing to the operational reliability of the electric system.

Keywords: System Quality, Quality Indicators, Artificial Neural Networks, Estimation of continuity indicators.

Sumário

CAPÍTULO 1: INTRODUÇÃO	12
1.2 OBJETIVOS.....	14
1.2.1 <i>Objetivos gerais</i>	14
1.2.2 <i>Objetivos específicos</i>	14
1.3 ORGANIZAÇÃO DO TRABALHO	14
CAPÍTULO 2: QUALIDADE DO SERVIÇO	15
2.1 INDICADORES DE TEMPO DE ATENDIMENTO ÀS OCORRÊNCIAS EMERGENCIAIS	15
2.2 INDICADORES INDIVIDUAIS DE CONTINUIDADE	18
2.3 COMPENSAÇÕES PELA VIOLAÇÃO DOS LIMITES INDIVIDUAIS DE CONTINUIDADE	19
2.4 CONJUNTO DE UNIDADES CONSUMIDORAS	21
2.5 INDICADORES COLETIVOS DE CONTINUIDADE	21
2.6 CONSIDERAÇÕES FINAIS	23
CAPÍTULO 3: REDES NEURAIS ARTIFICIAIS	24
3.1 HISTÓRICO.....	24
3.2 O NEURÔNIO ARTIFICIAL	25
3.3 FUNÇÕES DE ATIVAÇÃO.....	26
3.4 ARQUITETURAS DE REDE.....	28
3.4.1 <i>Redes Feedforward de uma única camada oculta</i>	28
3.4.2 <i>Redes Feedforward de múltiplas camadas</i>	29
3.4.3 <i>Redes recorrentes</i>	30
3.4.3.1 Modelo recorrente de entrada e saída	30
3.4.3.2 Modelo de espaço de estados	32
3.4.3.3 Perceptrons multicamadas recorrentes.....	32
3.4.3.4 Rede de segunda ordem	33
3.5 TREINAMENTO	35
3.6 TRANSFORMADA WAVELET	36
3.8 CONSIDERAÇÕES FINAIS	39
CAPÍTULO 4: DESENVOLVIMENTO DE MODELOS E RESULTADOS	40
4.1 SELEÇÃO DO CONJUNTO DE UNIDADES CONSUMIDORAS A SER ESTUDADO	40
4.2 METODOLOGIA	42
4.3 TRATAMENTO DOS DADOS	43
4.3.1 <i>Segmentação semanal</i>	43
4.3.2 <i>Tratamento de Outliers</i>	43
4.3.3 <i>Raiz quadrada e Oscilação dos dados</i>	45
4.3.4 <i>Transformada Wavelet</i>	46
4.3.5 <i>Normalização</i>	48
4.3.6 <i>Interpolação</i>	48
4.4 TREINAMENTO E PREVISÃO DA REDE NEURAL	50
4.5 PREVISÃO DOS INDICADORES DE CONTINUIDADE	51
4.5.1 <i>Resultados Individuais de Previsão do Indicador DEC</i>	51
4.5.2 <i>Resultados Individuais de Previsão do Indicador FEC</i>	59
4.5.3 <i>Resultados de Previsão Mensais do Indicador DEC</i>	67
4.5.3 <i>Resultados de Previsão Mensal do Indicador FEC</i>	71
4.6 ANÁLISE	75
CAPÍTULO 5: CONCLUSÕES	77
REFERÊNCIAS BIBLIOGRÁFICAS	78

Lista de Figuras

Figura 1 - Tempo de Atendimento em minutos da EDP Espírito Santo.....	17
Figura 2 - Número de Ocorrências e PNIE da EDP Espírito Santo	17
Figura 3 - Indicadores globais de continuidade e limites a nível Brasil.....	23
Figura 4 - Indicadores globais de continuidade e limites da EDP Espírito Santo	23
Figura 5 - Modelo de um neurônio	25
Figura 6 - Função limiar	27
Figura 7 - Função sigmóide logística	27
Figura 8 - Função sigmóide tangente hiperbólica	28
Figura 9 - Rede <i>feedforward</i> com uma única camada de neurônios	29
Figura 10 - Rede <i>feedforward</i> com uma camada oculta e uma camada de saída.	29
Figura 11 - Rede recorrente de camada única	30
Figura 12 - Modelo autorregressivo não linear com entradas exógenas (NARX)	31
Figura 13 - Modelo de espaço de estados.....	32
Figura 14 - Perceptron multicamada recorrente	33
Figura 15 - Rede recorrente de segunda ordem.....	34
Figura 16 - Exemplo de dilatação de uma função <i>Wavelet</i>	37
Figura 17 - Exemplo de translação de uma função <i>Wavelet</i>	38
Figura 18 - Processo de decomposição do sinal	39
Figura 19 - Diagrama do tratamento de dados realizado.....	43
Figura 20 - Resultado do método de tratamento de <i>outliers</i> adotado.....	44
Figura 21 - Identificação de amostras contendo <i>outliers</i>	45
Figura 22 - Resultado do método de tratamento de dados para melhorar o desempenho da função de ativação.....	46
Figura 23 - MODWT: Série decomposta em 8 subséries.....	47
Figura 24 - Sinal de baixa, média e alta frequência a partir da MODWT.....	47
Figura 25 - Normalização dos dados de baixa, média e alta frequência	48
Figura 26 - Interpolação de dados utilizando a função <i>spline</i> do Matlab.....	49
Figura 27 - Interpolação dos dados.....	49
Figura 28 - Sinal de entrada original e sem <i>outliers</i> para previsão do DEC do dia 10 de janeiro de 2016.....	51
Figura 29 - Sinal de entrada original e sem <i>outliers</i> para previsão do DEC do dia 11 de janeiro de 2016.....	52
Figura 30 - Previsão da subsérie de baixa frequência (BF) do indicador DEC com Horizonte de Previsão (HP) = 1 do dia 10 de janeiro de 2016, utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	53

Figura 31 - Previsão da subsérie de média frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal sem tratamento de <i>outliers</i> como entrada	53
Figura 32 - Previsão da subsérie de alta frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	54
Figura 33 - Previsão da subsérie de baixa frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.	54
Figura 34 - Previsão da subsérie de média frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.	55
Figura 35 - Previsão da subsérie de alta frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	55
Figura 36 - Previsão da subsérie de baixa frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal com tratamento de <i>outliers</i> como entrada.....	56
Figura 37 - Previsão da subsérie de média frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal com tratamento de <i>outliers</i> como entrada.....	57
Figura 38 - Previsão da subsérie de alta frequência do indicador DEC do dia 10 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.	57
Figura 39 - Previsão da subsérie de baixa frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.....	58
Figura 40 - Previsão da subsérie de média frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.....	58
Figura 41 - Previsão da subsérie de alta frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.	59
Figura 42 - Sinal de entrada original e sem <i>outliers</i> para previsão do FEC do dia 17 de janeiro de 2016.....	59
Figura 43 - Sinal de entrada original e sem <i>outliers</i> para previsão do FEC do dia 18 de janeiro de 2016.....	60
Figura 44 - Previsão da subsérie de baixa frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	61
Figura 45 - Previsão da subsérie de média frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.	61
Figura 46 - Previsão da subsérie de alta frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	62
Figura 47 - Previsão da subsérie de baixa frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	62
Figura 48 - Previsão da subsérie de média frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.	63
Figura 49 - Previsão da subsérie de alta frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	63
Figura 50 - Previsão da subsérie de baixa frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.	64
Figura 51 - Previsão da subsérie de média frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.....	65

Figura 52 - Previsão da subsérie de alta frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.	65
Figura 53 - Previsão da subsérie de baixa frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.	66
Figura 54 - Previsão da subsérie de média frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.....	66
Figura 55 - Previsão da subsérie de alta frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.	67
Figura 56 – <i>Boxplot</i> do erro percentual do DEC para os sinais de: (a) baixa frequência, (b) média frequência, (c) alta frequência.	70
Figura 57 – Resultados de previsão do indicador DEC para o mês de janeiro de 2016.....	71
Figura 58 - Resultados de previsão do indicador DEC para o mês de fevereiro de 2016.	71
Figura 59 - <i>Boxplot</i> do erro percentual do FEC para os sinais de: (a) baixa frequência, (b) média frequência, (c) alta frequência.	74
Figura 60 - Resultados de previsão do indicador FEC para o mês de janeiro de 2016	75
Figura 61 - Resultados de previsão do indicador FEC para o mês de fevereiro de 2016.....	75

Lista de Tabelas

Tabela 1 - Melhor configuração de rede do indicador DEC na previsão do dia 10 de jan. 2016, utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	52
Tabela 2 - Melhor configuração de rede do indicador DEC na previsão do dia 11 de jan. 2016, utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	52
Tabela 3 - Melhor configuração de rede do indicador DEC na previsão do dia 10 de jan. 2016, utilizando o sinal com tratamento de <i>outliers</i> como entrada	56
Tabela 4 - Melhor configuração de rede do indicador DEC na previsão do dia 11 de jan. 2016, utilizando o sinal com tratamento de <i>outliers</i> como entrada	56
Tabela 5 - Melhor configuração de rede do indicador FEC na previsão do dia 17 de jan. 2016, utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	60
Tabela 6 - Melhor configuração de rede do indicador FEC na previsão do dia 18 de jan. 2016, utilizando o sinal sem tratamento de <i>outliers</i> como entrada.....	60
Tabela 7 - Melhor configuração de rede do indicador FEC na previsão do dia 17 de jan. 2016, utilizando o sinal com tratamento de <i>outliers</i> como entrada	64
Tabela 8 - Melhor configuração de do indicador FEC na previsão do dia 18 de jan. 2016 utilizando o sinal com tratamento de <i>outliers</i> como entrada.	64
Tabela 9 - Melhor configuração de rede encontrada para cada subsérie do indicador DEC na previsão dos dias de jan. 2016.	68
Tabela 10 - DEC real e previsto a partir do modelo com RNA.....	71
Tabela 11 - Melhor configuração de rede encontrada para cada subsérie do indicador FEC na previsão dos dias de jan. 2016.	72
Tabela 12 - FEC real, previsto pelo método da distribuidora e previsto a partir do modelo com RNA.	75

Capítulo 1: Introdução

Nos últimos anos, o setor elétrico brasileiro tem sofrido um processo de grandes mudanças em sua estrutura. No ano de 1991, o governo federal criou o Programa Nacional de Desestatização (PND). Segundo Pires (2000), o governo priorizou a venda das empresas do segmento de distribuição por entender que dificilmente conseguiria atrair interessados para os ativos de geração caso não houvesse a perspectiva de um mercado atacadista privado de energia.

A Espírito Santo Centrais Elétricas SA (ESCELSA) foi a primeira concessionária a ser privatizada. A sua privatização ocorreu no ano de 1995. Esta nova realidade obrigou o governo brasileiro implementar diversas mudanças no setor elétrico (ARAÚJO, 2016).

A primeira grande mudança aconteceu em 1996, com a criação da Agência Nacional de Energia Elétrica (ANEEL), que estabeleceu um conjunto de exigências, obrigações, procedimentos, indicadores de natureza técnica e comercial, além de penalidades, com o objetivo de assegurar a qualidade dos serviços prestados por essas empresas aos consumidores (DIAS, 2002).

Para medir o desempenho e a confiabilidade de sistemas de distribuição de energia, a partir do aspecto da qualidade do produto, existem alguns indicadores de qualidade estabelecidos pela ANEEL. Dentre eles, destacam-se a Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e a Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), estipulados segundo os procedimentos referentes à Qualidade da Energia Elétrica (QEE), estabelecidos no Módulo 8 dos Procedimentos de Distribuição – PRODIST (ANEEL, 2018b).

Em caso de violação das metas estabelecidas no período de apuração, as concessionárias deverão sofrer penalidades (SPERANDIO, 2004), que vão desde um plano de melhorias, no qual a concessionária deve elaborar um plano para atingir as metas de seus conjuntos e apresentá-lo ao órgão fiscalizador, bem como a realização de compensações aos consumidores. Por outro lado, o bom desempenho em tais indicadores é recompensado pela ANEEL, por meio de ajuste tarifário anual, como incentivo à busca pela melhoria contínua da qualidade do serviço. Conforme dados da ANEEL (ANEEL, 2017a), no Brasil as concessionárias realizaram uma quantidade de 125,20 milhões de compensações em 2015, 110,98 milhões em 2016 e 78,66 milhões em 2017, que refletiram em valores de R\$ 656,89 milhões, R\$ 571,13 milhões e R\$ 381,90 milhões, respectivamente.

O conhecimento, a priori, dos indicadores de continuidade DEC e FEC, pode auxiliar na definição de prioridades para distribuir de forma mais eficaz os investimentos e recursos para a redução de problemas no sistema elétrico, trazendo como consequência direta desde investimentos a melhorias subsequentes dos índices de confiabilidade (TRONCHONI, 2008). Nesse aspecto, alguns trabalhos vêm sendo desenvolvidos de forma que se possa prever, com o menor erro, os indicadores de continuidade DEC e FEC.

Em Dias (2002) é apresentada uma metodologia capaz de quantificar os impactos de vários tipos de ações de engenharia nos indicadores de continuidade de forma a prever – ainda na etapa de planejamento – como cada uma das opções de obras afetará a confiabilidade do fornecimento.

Em Coelho e outros (2003), é apresentado um estudo que busca investigar a influência das condições climáticas nos níveis de confiabilidade de um sistema de distribuição de energia elétrica (índices de continuidade, frequência e duração de falhas, *System Average Interruption Frequency Index* - SAIFI e *System Average Interruption Duration Index* - SAIDI, respectivamente). Os autores concluíram que o número de interrupções é maior na presença de alta umidade relativa e precipitação.

A pesquisa realizada por Magalhães (2017) propõe o desenvolvimento de modelos, utilizando técnicas de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA), que realizem a previsão dos valores dos indicadores de continuidade DEC e FEC. Segundo o autor, os melhores modelos avaliados, tanto para o DEC como para o FEC, foram os baseados nas técnicas de RNA com restrição de parâmetros negativos.

Na mesma linha de pesquisa, Araújo (2016) desenvolveu um método de predição de indicadores de continuidade DEC e FEC, utilizando-se um modelo matemático de Análise de Regressão Linear Múltipla (ARLM). Segundo o autor, o melhor desempenho foi obtido pelo modelo ARLM em que foram retirados os pontos de *outliers*.

1.2 Objetivos

1.2.1 Objetivos gerais

Propor uma metodologia para tratamento de dados e previsão dos indicadores de continuidade DEC e FEC de um conjunto elétrico utilizando redes neurais artificiais.

1.2.2 Objetivos específicos

Os objetivos deste trabalho são os seguintes:

- Estudar e determinar as RNA de possível aplicação à seleção de dados tabelados;
- Realizar o tratamento dos dados para melhor desempenho da previsão das redes neurais;
- Analisar dados reais de indicadores de continuidade para seleção de rede neural apropriada;
- Utilizar uma RNA para prever os indicadores de continuidade para ações prévias de manutenção, buscando a mitigação de violações e realização de compensações;
- Agregar ao acervo técnico da pós-graduação material sobre redes neurais aplicada a previsão de indicadores de continuidade da distribuição.

1.3 Organização do Trabalho

Este trabalho está organizado conforme segue. No primeiro Capítulo é apresentada uma contextualização do estudo e estabelecidos os objetivos do trabalho. O Capítulo 2 traz uma revisão bibliográfica dos indicadores de qualidade de energia elétrica, abordando conceitos importantes que serão utilizados no decorrer do trabalho. No Capítulo 3 é realizada uma revisão bibliográfica que trata das redes neurais. No Capítulo 4 se encontra a metodologia, com detalhamento de todas as etapas realizadas, definição das variáveis, tratamento dos dados, implementação da rede neural e apresentação dos resultados. Por fim, o Capítulo 5 se dedica às conclusões e propostas de continuidade do trabalho.

Capítulo 2: Qualidade do Serviço

No Brasil, a distribuição de energia elétrica é normatizada e padronizada pela Agência Nacional de Energia Elétrica (ANEEL), através dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST). Hoje, o PRODIST possui onze módulos (ANEEL, 2018a), a saber:

- Módulo 1 - Introdução
- Módulo 2 - Planejamento da Expansão do Sistema de Distribuição
- Módulo 3 - Acesso ao Sistema de Distribuição
- Módulo 4 - Procedimentos Operativos do Sistema de Distribuição
- Módulo 5 - Sistemas de Medição
- Módulo 6 - Informações Requeridas e Obrigações
- Módulo 7 - Cálculo de Perdas na Distribuição
- Módulo 8 - Qualidade da Energia Elétrica
- Módulo 9 - Ressarcimento de Danos Elétricos
- Módulo 10 - Sistema de Informação Geográfica Regulatório
- Módulo 11 - Fatura de Energia Elétrica e Informações Suplementares

Por meio do Módulo 8 do PRODIST (ANEEL, 2018b), a ANEEL define indicadores e seus limites para mensurar o nível da qualidade de energia que a distribuidora está entregando a seus clientes.

2.1 Indicadores de Tempo de Atendimento às Ocorrências Emergenciais

Os indicadores de tempo de atendimento às ocorrências emergenciais são (ANEEL, 2018b):

- Tempo Médio de Preparação (TMP): indicador que mede a eficiência dos meios de comunicação, dimensionamento das equipes e dos fluxos de informação dos Centros de operação e é definido por (2.1).

$$TMP = \frac{\sum_{i=1}^n TP(i)}{n} \quad (2.1)$$

- Tempo Médio de Deslocamento (TMD): indicador que mede a eficácia da localização geográfica das equipes de manutenção e operação e é definido por (2.2).

$$TMD = \frac{\sum_{i=1}^n TD(i)}{n} \quad (2.2)$$

- Tempo Médio de Execução (TME): indicador que mede a eficácia do restabelecimento do sistema de distribuição pelas equipes de manutenção e operação e é definido por (2.3).

$$TME = \frac{\sum_{i=1}^n TE(i)}{n} \quad (2.3)$$

- Tempo Médio de Atendimento a Emergências (TMAE): que é definido por (2.4).

$$TMAE = TMP + TMD + TME \quad (2.4)$$

- Percentual do Número de ocorrências emergenciais com Interrupção de Energia (PNIE): que é definido por (2.5).

$$PNIE = \frac{NIE}{n} * 100 \quad (2.5)$$

onde:

TMP = tempo médio de preparação da equipe de atendimento de emergência, expresso em minutos;

TP = tempo de preparação da equipe de atendimento de emergência para cada ocorrência emergencial, expresso em minutos;

n = número de ocorrências emergenciais verificadas no conjunto de unidades consumidoras, no período de apuração considerado;

TMD = tempo médio de deslocamento da equipe de atendimento de emergência, expresso em minutos;

TD = tempo de deslocamento da equipe de atendimento de emergência para cada ocorrência emergencial, expresso em minutos;

TME = tempo médio de execução do serviço até seu restabelecimento pela equipe de atendimento de emergência, expresso em minutos;

TE = tempo de execução do serviço até seu restabelecimento pela equipe de atendimento de emergência para cada ocorrência emergencial, expresso em minutos;


TMAE = tempo médio de atendimento a ocorrências emergenciais, representando o tempo médio para atendimento de emergência, expresso em minutos;

PNIE = percentual do número de ocorrências emergenciais com interrupção de energia elétrica, expresso em porcentagem;

NIE = número de ocorrências emergenciais com interrupção de energia elétrica.


Na Figura 1 é exibido o histórico destes indicadores para a EDP Espírito Santo.

Figura 1 - Tempo de Atendimento em minutos da EDP Espírito Santo



Fonte: Adaptado de ANEEL (2018).

Figura 2 - Número de Ocorrências e PNIE da EDP Espírito Santo



Fonte: Adaptado de ANEEL (2018).

2.2 Indicadores Individuais de Continuidade

Os indicadores individuais de continuidade do serviço de distribuição de energia elétrica com apuração mensal são:

- Duração de Interrupção Individual por Unidade Consumidora ou por Ponto de Conexão (DIC), definido por (2.6):

$$DIC = \sum_{i=1}^n t(i) \quad (2.6)$$

- Frequência de Interrupção Individual por Unidade Consumidora ou por Ponto de Conexão (FIC), definido por (2.7):

$$FIC = n \quad (2.7)$$

- Duração Máxima de Interrupção Contínua por Unidade Consumidora ou por Ponto de Conexão (DMIC), definido por (2.8):

$$DMIC = t_{max}(i) \quad (2.8)$$

- Duração da Interrupção Individual ocorrida em Dia Crítico por unidade consumidora ou ponto de conexão (DICRI), definido por (2.9):

$$DICRI = t_{crítico} \quad (2.9)$$

onde:

i = índice de interrupções da unidade consumidora no período de apuração, variando de 1 a n ;

n = número de interrupções da unidade consumidora considerada, no período de apuração;

$t(i)$ = tempo de duração da interrupção (i) da unidade consumidora considerada ou ponto de conexão, no período de apuração;

$t_{max}(i)$ = valor correspondente ao tempo da máxima duração de interrupção contínua (i), no período de apuração, verificada na unidade consumidora considerada, expresso em horas e centésimos de horas;

$t_{\text{crítico}}$ = duração da interrupção ocorrida em Dia Crítico. O Dia Crítico é um dia em que a quantidade de ocorrências emergenciais, em um determinado conjunto de unidades consumidoras, supera a média acrescida de três desvios padrões dos valores diários dessas. A média e o desvio padrão a serem usados serão os relativos aos 24 (vinte e quatro) meses anteriores ao ano em curso, incluindo os dias críticos já identificados.

Para os indicadores de continuidade individuais, são estabelecidos, nas tabelas de 1 a 5 do Anexo I do Módulo 8 do PRODIST (ANEEL, 2018b), limites que, caso sejam violados, a distribuidora deverá realizar uma compensação ao cliente.

2.3 Compensações Pela Violação dos Limites Individuais de Continuidade

De acordo com o Módulo 8 do PRODIST (ANEEL, 2018b), caso ocorra violação do limite de continuidade individual dos indicadores DIC, FIC, DMIC e/ou DICRI em relação ao período de apuração (mensal, trimestral ou anual), a distribuidora deverá realizar uma compensação, por meio de crédito na fatura, em até dois meses após o período de apuração.

Para se obter o valor da compensação a ser realizada, deverão ser utilizadas as seguintes fórmulas:

Para o DIC:

$$Valor = \left(\frac{DICv}{DICp} - 1 \right) * DICp * \frac{EUSDmédio}{730} * kei \quad (2.10)$$

Para o DMIC:

$$Valor = \left(\frac{DMICv}{DMICp} - 1 \right) * DMICp * \frac{EUSDmédio}{730} * kei \quad (2.11)$$

Para o FIC:

$$Valor = \left(\frac{FICv}{FICp} - 1 \right) * DICp * \frac{EUSDmédio}{730} * kei \quad (2.12)$$

Para o DICRI:

$$Valor = \left(\frac{DICRIv}{DICRIp} - 1 \right) * DICRIp * \frac{EUSDmédio}{730} * kei \quad (2.13)$$

onde:

DICv = duração de interrupção por unidade consumidora ou por ponto de conexão, conforme cada caso, verificada no período considerado, expressa em horas e centésimos de hora;

DICp = limite de continuidade estabelecido no período considerado para o indicador de duração de interrupção por unidade consumidora ou por ponto de conexão, expresso em horas e centésimos de hora;

DMICv = duração máxima de interrupção contínua por unidade consumidora ou por ponto de conexão, conforme cada caso, verificada no período considerado, expressa em horas e centésimos de hora;

DMICp = limite de continuidade estabelecido no período considerado para o indicador de duração máxima de interrupção contínua por unidade consumidora ou por ponto de conexão, expresso em horas e centésimos de hora;

FICv = frequência de interrupção por unidade consumidora ou por ponto de conexão, conforme cada caso, verificada no período considerado, expressa em número de interrupções;

FICp = limite de continuidade estabelecido no período considerado para o indicador de frequência de interrupção por unidade consumidora ou por ponto de conexão, expresso em número de interrupções e centésimo do número de interrupções;

DICRIv = duração da interrupção individual ocorrida em Dia Crítico por unidade consumidora ou ponto de conexão, expressa em horas e centésimos de hora;

DICRIp = limite de continuidade estabelecido para o indicador de duração da interrupção individual ocorrida em Dia Crítico por unidade consumidora ou ponto de conexão, expresso em horas e centésimos de hora;

EUSDmédio = média aritmética dos encargos de uso do sistema de distribuição correspondentes aos meses do período de apuração do indicador;

730 = número médio de horas no mês;

kei = coeficiente de majoração cujo valor deve ser fixado em:

- i. 15 (quinze), para unidade consumidora ou ponto de conexão atendidos em Baixa Tensão;
- ii. 20 (vinte), para unidade consumidora ou ponto de conexão atendidos em Média Tensão;
- iii. 27 (vinte e sete), para unidade consumidora ou ponto de conexão atendidos em Alta Tensão.

Conforme dados da ANEEL (ANEEL, 2017a), no Brasil, as concessionárias pagaram uma quantidade de 125,20 milhões de compensações em 2015, 111,61 milhões em 2016, e 100,38 milhões em 2017 que totalizaram valores de R\$ 656,89 milhões, R\$ 573,42 milhões e R\$ 492,36 milhões, respectivamente. Já a EDP Espírito Santo realizou uma quantidade de 1

milhão de compensações em 2015, 1 milhão em 2016 e 0,90 milhão em 2017 que refletiram em valores de R\$ 4,74 milhões, R\$ 4,88 milhões e R\$ 4,02 milhões, nesta ordem.

2.4 Conjunto de Unidades Consumidoras

A ANEEL, ainda por meio de do Módulo 8 do PRODIST (ANEEL, 2018b), define um conjunto de unidades consumidoras por Subestação de Distribuição (SED) tendo como abrangência as redes MT à jusante da SED que sejam de propriedade da distribuidora. Com relação à agregação de SED para formação de um único conjunto, devem ser obedecidos os seguintes critérios:

- SED que possuam número de unidades consumidoras igual ou inferior a 1.000 devem ser agregadas a outras, formando um único conjunto;
- SED com número de unidades consumidoras superior a 1.000 e igual ou inferior a 10.000 podem ser agregadas a outras, formando um único conjunto;
- A agregação de SED deve obedecer ao critério de contiguidade das áreas;
- É vedada a agregação de duas ou mais SED cujos números de unidades consumidoras sejam superiores a 10.000;
- Mediante aprovação da ANEEL, poderão formar diferentes conjuntos SED que atendam a áreas não contíguas, ou que atendam a subestações MT/MT cujas características de atendimento sejam muito distintas da subestação supridora, desde que nenhum dos conjuntos resultantes possua número de unidades consumidoras igual ou inferior a 1.000. Na segunda hipótese, a fronteira dos conjuntos deverá corresponder à entrada da subestação MT/MT;
- Poderão ser divididas, mediante aprovação da ANEEL, SED com redes subterrâneas e aéreas, devendo os conjuntos resultantes possuir número de unidades consumidoras superior a 1.000.

2.5 Indicadores Coletivos de Continuidade

Além dos indicadores de continuidade individuais com período de apuração mensal, também são definidos os indicadores de continuidade de conjunto de unidades consumidoras com igual período de apuração por meio de do Módulo 8 do PRODIST (ANEEL, 2018b):

- Duração Equivalente de Interrupção por Unidade Consumidora (DEC), definido por (2.14):

$$DEC = \frac{\sum_{i=1}^{Cc} DIC(i)}{Cc} \quad (2.14)$$

- Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), estabelecido por (2.15):

$$FEC = \frac{\sum_{i=1}^{Cc} FIC(i)}{Cc} \quad (2.15)$$

onde:

i = índice de unidades consumidoras atendidas em BT ou MT faturadas do conjunto;
Cc = número total de unidades consumidoras faturadas do conjunto no período de apuração, atendidas em BT ou MT.

Estes indicadores também devem ser apurados em um período trimestral e anual, os quais são definidos por (2.16), (2.17), (2.18) e (2.19):

$$DEC_{TRIM} = \frac{\sum_{n=1}^3 DEC_n * Cc_n}{Cc_{MED_TRIM}} \quad (2.16)$$

$$FEC_{TRIM} = \frac{\sum_{n=1}^3 FEC_n * Cc_n}{Cc_{MED_TRIM}} \quad (2.17)$$


$$DEC_{ANUAL} = \frac{\sum_{n=1}^{12} DEC_n * Cc_n}{Cc_{MED_ANUAL}} \quad (2.18)$$

$$FEC_{ANUAL} = \frac{\sum_{n=1}^{12} FEC_n * Cc_n}{Cc_{MED_ANUAL}} \quad (2.19)$$

Por fim, ainda podem ser calculados os indicadores de continuidade de desempenho global que se referem a um agrupamento de conjuntos de unidades consumidoras, podendo se referir a uma distribuidora, município, estado, região ou ao Brasil. Em 2018, os limites propostos dos indicadores globais da distribuidora EDP Espírito Santo são 9,73 horas para o DEC e 7,27 interrupções para o FEC, conforme definido pela Nota Técnica nº 0106/2016-SRD/ANEEL, de 19/07/2016 (ANEEL, 2016).

Nas Figuras 3 e 4 são exibidos o histórico dos indicadores DEC e FEC a nível Brasil e da concessionária EDP Espírito Santo, respectivamente, com seus limites.

Figura 3 - Indicadores globais de continuidade e limites a nível Brasil



Fonte: Adaptado de ANEEL (2018).

Figura 4 - Indicadores globais de continuidade e limites da EDP Espírito Santo



Fonte: Adaptado de ANEEL (2018).

2.6 Considerações Finais

Neste capítulo foram apresentados os indicadores e as compensações no âmbito da qualidade do serviço. Desta forma, a previsão dos indicadores de continuidade se mostra importante, pois permite, a priori, melhor distribuir as equipes de atendimento, diminuir os tempos de atendimento e de energia interrompida, reduzir os valores pagos de compensação e melhorar a avaliação de desempenho da distribuidora.

No próximo capítulo será apresentado um resumo teórico sobre redes neurais artificiais, análise estatística e Transformada Wavelet.

Capítulo 3: Redes Neurais Artificiais

3.1 Histórico

De acordo com Haykin (2009) uma rede neural é uma máquina projetada para modelar uma forma semelhante ao que um cérebro humano utiliza para realizar uma determinada tarefa ou função de interesse. Assim como no cérebro humano, o neurônio é uma unidade de processamento fundamental para uma rede neural.

Os primeiros documentos que mencionam pesquisas relacionadas às redes neurais datam de 1943, quando o psiquiatra e neuroanatomista Warren McCulloch e o matemático Walter Pitts projetaram a estrutura que ficou conhecida como a primeira rede neural (FINOCCHIO, 2014). A pesquisa tinha como objetivo criar um modelo artificial para o neurônio biológico, conhecido como Neurônio Booleano de McCulloch-Pitts MCP, e apresentar suas capacidades computacionais. Muitas outras pesquisas surgiram desde então, porém pouco resultado foi obtido. Em 1949, Donald O. Hebb apresentou uma hipótese sobre como a força das sinapses no cérebro se altera em resposta à experiência. Esta hipótese passou a influir decisivamente na evolução da teoria de aprendizagem das RNA (FINOCCHIO, 2014).

O primeiro neurocomputador a obter sucesso surgiu por volta de 1958. Ele foi criado por Frank Rosenblatt, Charles Wightman e outros. Rosenblatt introduziu uma nova abordagem para o problema de reconhecimento de padrões com o desenvolvimento do Perceptron, que é o primeiro algoritmo a descrever uma rede neural (MÓDOLO, 2016). Ele também propôs para o neurocomputador (Mark I Perceptron) um algoritmo para o ajuste dos pesos. Porém, esse modelo não era capaz de resolver algumas tarefas simples e poucas pesquisas foram desenvolvidas, até que, em 1982, John Hopfield mostrou as propriedades associativas das RNA, o que marcou a retomada das pesquisas.


Segundo Finocchio (2014), nomes como Teuvo Kohonen, Stephen Grossberg, B. Widrow, James Anderson, Edoardo Caianiello, Kunuhito Fukushima, Igor Aleksander, entre outros, conseguiram novamente estabelecer um campo concreto para o renascimento da área. Eles passaram a publicar diversas propostas para o desenvolvimento e para as aplicações de redes neurais. Esta retomada do interesse pela exploração das RNA deu-se por vários fatores, como, por exemplo, melhores conhecimentos da estrutura real do cérebro, a disponibilidade de computadores com maior capacidade de cálculo e o desenvolvimento de novos algoritmos de aprendizado.

Nos anos 80, muitos fatores contribuíram para o ressurgimento definitivo das pesquisas em redes neurais e, conseqüentemente, permitindo a sua aplicação em sistemas reais. Em 1986, com a criação do algoritmo de treinamento por *backpropagation*, por Rumelhart, Campbell e Borgetti, as RNA se tornaram capazes de resolver problemas considerados “difíceis” (MÓDOLO, 2016).

Desde então, várias aplicações têm sido mapeadas através de redes neurais artificiais, tais como: reconhecimento de padrões, processamento de imagens, sistemas de controle, robótica e identificação de sistemas (FINOCCHIO, 2014).

3.2 O neurônio artificial

Na Figura 5 é mostrado o modelo de um neurônio artificial utilizado para criação de uma rede neural.



Fonte: Adaptado de HAYKIN (2009)

Um neurônio artificial é composto por três elementos básicos:

- Conjunto de sinapses: onde os sinais de entrada são inseridos e multiplicados por um peso específico.
- Um somador: utilizado para somar os sinais de entrada ponderados pelos respectivos pesos.
- Função de ativação: responsável por limitar a amplitude de saída de um neurônio.

O modelo de neurônio da Figura 5 também possui uma entrada externa, denotada por b_k , cujo objetivo é aumentar ou diminuir a entrada na função de ativação, dependendo se seu

valor é positivo ou negativo, respectivamente. Matematicamente, o neurônio da Figura 5 pode ser descrito por (3.1) e (3.2).

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$

$$y_k = \varphi(u_k + b_k) \quad (3.2)$$

onde:

x_j = sinais de entrada;

w_{kj} = pesos sinápticos;

u_k = somatório dos sinais de entrada multiplicados pelos pesos sinápticos;

b_k = sinal de *bias*;

φ = saída da função de ativação;

y_k = saída do neurônio.

3.3 Funções de Ativação

A função de ativação, determinada por $\varphi(v_k)$, define a saída do neurônio em função de v_k . Há três tipos básicos de funções de ativação:

a) Função limiar


$$\varphi(v_k) = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (3.3)$$

onde v_k é descrito por (3.4).

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (3.4)$$

Um neurônio com esta função de ativação é definido como o modelo de McCulloch-Pitts, em reconhecimento ao trabalho pioneiro feito por McCulloch e Pitts (1943). Neste modelo, a saída do neurônio assume o valor de 1 se v_k é não negativo e -1 se for negativo, como ilustrado na Figura 6.

Figura 6 - Função limiar



Fonte: SEVERO (2010)


b) Função sigmóide logística

É a função de ativação mais comum na construção de redes neurais. Esta função é estritamente crescente, mantendo um equilíbrio entre um comportamento linear e não linear. A faixa de valores possíveis para a função sigmóide logística é o intervalo fechado $[0,1]$. Um exemplo de função sigmóide é mostrado em (3.5).

$$\varphi(v_k) = \frac{1}{1 + e^{-av_k}} \quad (3.5)$$

onde a é o parâmetro de inclinação da função sigmóide. A Figura 7 apresenta a função sigmóide logística.

Figura 7 - Função sigmóide logística



Fonte: SEVERO (2010)


c) Função sigmóide tangente hiperbólica

Esta função é estritamente crescente, mantendo um equilíbrio entre um comportamento linear e não linear. A faixa de valores possíveis para a função sigmóide tangente hiperbólica é o intervalo fechado $[-1, +1]$. A equação (3.6) é um exemplo de função tangente hiperbólica.

$$\varphi(v_k) = \frac{1 - e^{-av_k}}{1 + e^{-av_k}} \quad (3.6)$$

onde a é o parâmetro de inclinação da função tangente hiperbólica. A Figura 8 representa a função sigmóide tangente hiperbólica.

Figura 8 - Função sigmóide tangente hiperbólica



Fonte: SEVERO (2010)


3.4 Arquiteturas de rede

A forma de estruturação dos neurônios de uma rede neural artificial está diretamente ligada com o algoritmo de aprendizagem usado para treinar a rede. De acordo com Haykin (2009), as arquiteturas de rede podem ser classificadas em três tipos.

3.4.1 Redes *Feedforward* de uma única camada oculta

É a arquitetura mais simples, onde a rede é composta por uma camada de nós de entrada ligada diretamente em uma camada de saída de neurônios. Esta rede é chamada de rede de camada única. A camada de entrada não é contabilizada, pois não há processamento nela. Esta rede é estritamente do tipo *feedforward* e sua arquitetura está ilustrada na Figura 9.

Figura 9 - Rede *feedforward* com uma única camada de neurônios




Fonte: Adaptado de HAYKIN (2009)

3.4.2 Redes *Feedforward* de múltiplas camadas

Essa arquitetura se distingue da anterior pela presença de uma ou mais camadas ocultas, ou seja, possui uma ou mais camadas de neurônios que não é vista diretamente da entrada ou da saída da rede. Nesta arquitetura, os neurônios de cada camada da rede têm como insumos os sinais de saída da camada anterior, de modo que o conjunto de sinais de saída dos neurônios da última camada da rede constituem a resposta global da rede aos dados de entrada na primeira camada. A Figura 10 ilustra uma rede 10-4-2, porque tem 10 nós de entrada, 4 neurônios ocultos e 2 neurônios de saída.

Figura 10 - Rede *feedforward* com uma camada oculta e uma camada de saída.




Fonte: Adaptado de HAYKIN (2009)

Nota-se que redes do tipo *feedforward* não utilizam o sinal de saída de uma camada como entrada para camadas anteriores. Uma RNA é considerada totalmente conectada se, e somente se, os neurônios de uma camada estiverem conectados a todos os neurônios da camada seguinte. Caso não seja totalmente conectada, a rede é considerada parcialmente conectada (ADERALDO, 2017).

3.4.3 Redes recorrentes

As redes recorrentes possuem uma característica fundamental, a existência de pelo menos um laço de realimentação. A realimentação consiste em utilizar sinais de saída de uma determinada camada/neurônio como entrada para uma outra camada/neurônio que seja anterior a esta, conforme é ilustrado na Figura 11.

Figura 11 - Rede recorrente de camada única



Fonte: TRONCHONI, 2008.

A arquitetura de uma rede recorrente pode assumir muitas formas diferentes. Nesta subseção serão apresentadas quatro arquiteturas de rede específicas que compartilham os seguintes recursos comuns:

- Todas elas incorporam um Perceptron multicamadas estático ou partes dele;
- Todas elas exploram a capacidade de mapeamento não linear do Perceptron multicamadas.

3.4.3.1 Modelo recorrente de entrada e saída

A Figura 12 ilustra a arquitetura de uma rede recorrente genérica que segue naturalmente a partir de um Perceptron multicamadas. O modelo possui uma única entrada que


é aplicada a uma memória de linha de q unidades. Ele tem uma única saída que é enviada de volta à entrada através de outra memória de linha de atraso de derivação, também com q unidades. O conteúdo dessas duas memórias de linha de atraso de derivação é usado para alimentar a camada de entrada do Perceptron multicamadas.

A rede recorrente ilustrada na Figura 12 é referida como autorregressiva não linear com modelo de entradas exógenas, também conhecida como Rede Neural Autorregressiva Com Entradas Exógenas (NARX) e tem seu comportamento dinâmico descrito por (3.7).

$$y_{n+1} = F(y_n, \dots, y_{n-q+1}; u_n, \dots, u_{n-q+1}) \quad (3.7)$$

onde F é uma função não linear de seus argumentos.

Figura 12 - Modelo autorregressivo não linear com entradas exógenas (NARX)



Fonte: Adaptado de HAYKIN (2009)

Caso não existam variáveis exógenas a rede é determinada como autorregressiva não linear, também conhecida como NAR.

3.4.3.2 Modelo de espaço de estados

A Figura 13 mostra o diagrama de blocos de outra rede recorrente genérica, chamada de modelo de espaço de estados. Os neurônios ocultos definem o estado da rede. A saída da camada oculta é realimentada para a entrada por meio de um banco de atrasos de unidade de tempo. A camada de entrada consiste em uma junção de nós de *feedback* e nós de origem. A rede é conectada ao ambiente externo por meio dos nós de origem. O número de atrasos de unidade tempo usados para alimentar a saída de camada oculta de volta à camada de entrada determina a ordem do modelo.


Pode-se descrever o comportamento dinâmico do modelo a partir de (3.8) e (3.9).

$$\mathbf{x}_{n+1} = \mathbf{a}(\mathbf{x}_n, \mathbf{u}_n) \quad (3.8)$$

$$\mathbf{y}_n = \mathbf{B}\mathbf{x}_n \quad (3.9)$$

onde $\mathbf{a}$ é uma função não linear que caracteriza a camada oculta e $\mathbf{B}$ é a matriz de pesos sinápticos caracterizando a camada de saída. A camada oculta é não linear, enquanto a camada de saída é linear.

Figura 13 - Modelo de espaço de estados




Fonte: Adaptado de HAYKIN (2009)

3.4.3.3 Perceptrons multicamadas recorrentes

A arquitetura de rede Perceptron multicamadas recorrente (RMLP - *Recurrent Multilayer Perceptron*) possui uma ou mais camadas ocultas. Cada camada de computação de um RMLP possui um *feedback* em torno dele, conforme ilustrado na Figura 14 para o caso de um RMLP com duas camadas ocultas.

Figura 14 - Perceptron multicamada recorrente



Fonte: Adaptado de HAYKIN (2009)

O comportamento dinâmico geral do RMLP em resposta a um vetor de entrada u_n é descrito por um sistema de equações acopladas, mostradas em (3.10).

$$\begin{aligned}
 X_{I,n+1} &= \Phi_I(X_{I,n}, u_n) \\
 X_{II,n+1} &= \Phi_{II}(X_{II,n}, X_{I,n+1}) \\
 &\dots \\
 X_{O,n+1} &= \Phi_0(X_{O,n}, X_{K,n+1})
 \end{aligned} \tag{3.10}$$

onde $X_{I,n}$ representa a saída da primeira camada oculta, $X_{II,n}$ descreve a saída da segunda camada oculta e assim por diante, $X_{O,n}$ significa a saída final da camada de saída, Φ_I , Φ_{II} e Φ_0 denotam as funções de ativação que caracterizam a primeira camada oculta, segunda camada oculta e a saída do RMLP, respectivamente. A variável K equivale ao número de camadas ocultas na rede, para esse caso, $K = II$.

3.4.3.4 Rede de segunda ordem

Considerando-se um Perceptron multicamadas, o campo local induzido v_k do neurônio k é definido por (3.11).

$$v_k = \sum_j w_{a,kj} x_j + \sum_i w_{b,ki} u_i \tag{3.11}$$

onde x_j é o sinal de *feedback* derivado do neurônio oculto, e x_j e u_i é o sinal de origem aplicado ao nó i na camada de entrada, os w representam os pesos sinápticos pertinentes na rede. O neurônio descrito por (3.11) é denominado neurônio de primeira ordem. Quando, no entanto, o

campo local induzido v_k é combinado usando multiplicações, conforme (3.12), o neurônio é denominado neurônio de segunda ordem. O neurônio k de segunda ordem usa um único peso que conecta aos nós de entrada i e j .

$$v_k = \sum_i \sum_j w_{kij} x_i u_j \quad (3.12)$$


Um exemplo de rede recorrente de segunda ordem é ilustrado na Figura 15. A rede aceita uma sequência de entradas de tempo e evolui com a dinâmica definida por (3.13) e (3.14).

$$v_{k,n} = b_k + \sum_i \sum_j w_{kij} x_{i,n} u_{j,n} \quad (3.13)$$

$$x_{k,n+1} = \frac{1}{1 + e^{-v_{k,n}}} \quad (3.14)$$

onde $v_{k,n}$ é o campo local induzido do neurônio oculto k , b_k é a polarização associada, $x_{k,n}$ é o estado (saída) do neurônio k , $u_{j,n}$ é a entrada aplicada ao nó de origem j e w_{kij} é o peso do neurônio de segunda ordem k .

Figura 15 - Rede recorrente de segunda ordem



Fonte: Adaptado de HAYKIN (2009)

3.5 Treinamento

A rede neural passa por um processo de treinamento com fundamentação nos casos reais conhecidos, adquirindo, a partir daí a sistemática necessária para executar adequadamente o processamento desejado. Ela é, portanto, capaz de extrair regras básicas (conjunto de pesos) em consequência dos dados reais (FINOCCHIO, 2014).

A propriedade mais importante das redes neurais é a habilidade de adquirir conhecimento através da experiência. Isso é feito através de um processo iterativo de ajustes (treinamento) aplicado a seus pesos. O processo de aprendizado encerra-se quando a rede neural consegue generalizar soluções para uma classe de problemas.

Todo o conhecimento de uma rede neural está armazenado nos pesos atribuídos às conexões entre os neurônios. Cerca de 60 a 90% do total de dados devem ser separados para o treinamento da rede neural a fim de que a rede “aprenda” as regras associadas ao processo. O restante dos dados só é apresentado à rede neural na fase de testes, para verificar se as regras produzem saídas adequadas para os dados não utilizados no treinamento (FINOCCHIO, 2014).

Segundo Aderaldo (2017), a habilidade de aprender e aperfeiçoar seu desempenho são as características mais importantes de uma RNA. Pode-se afirmar que parte do conhecimento da Rede Neural advém dos pesos sinápticos, uma vez que guardam os valores necessários para produzir a resposta desejada. Assim, no contexto de Redes Neurais, um algoritmo de aprendizagem é visto como um conjunto de regras responsáveis pelo ajuste dos pesos sinápticos

Existem duas formas básicas de aprendizado de redes neurais: aprendizado supervisionado e aprendizado não supervisionado.

Uma forma popular de aprendizado é o paradigma de aprendizado supervisionado, em que cada exemplo apresentado contém os parâmetros de entrada junto à resposta desejada. Um dos algoritmos mais utilizados de aprendizagem supervisionada é o algoritmo de retropropagação (*backpropagation*). Este algoritmo é baseado em correção de erro, para cada padrão apresentado é produzido um sinal que se propaga para frente, de camada a camada, até que se alcance a camada de saída. Em seguida, é comparada a resposta gerada com a resposta real, e a diferença entre o sinal de saída e a resposta desejada é conhecida como sinal de erro (ADERALDO, 2017). A diferença ou erro é então propagada da saída para a entrada e os pesos são alterados em conformidade com algum algoritmo que tende a minimizar esse erro ou diferença. Os vetores de entrada e saída do conjunto de treinamento são sequencialmente aplicados, as diferenças os erros são calculados e, para cada vetor, os pesos são ajustados até o erro atingir um nível aceitável para o conjunto de treinamento (FINOCCHIO, 2014).

A aprendizagem não supervisionada implica em apresentar dados de entrada sem suas respectivas respostas esperadas. Neste tipo de aprendizagem, somente os padrões de entrada estão disponíveis para a rede neural. A rede processa as entradas e, detectando suas regularidades, tenta progressivamente estabelecer representações internas para codificar características e classificá-las automaticamente. Este tipo de aprendizado só é possível quando existe redundância nos dados de entrada, para que se consiga encontrar padrões em tais dados (FERNEDA, 2006).

3.6 Transformada *Wavelet*

A Transformada de Fourier permite mapear um sinal no domínio do tempo para o domínio da frequência através da soma de ondas senoidais. Assim, a Transformada de Fourier (*Fourier Transform* – FT) de um sinal $x(t)$, denotada por $\mathcal{F}[x(t)]$, é definida por meio de (3.26):

$$X(f_s) = \mathcal{F}[x(t)] = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi f_s t} . dt \quad (3.26)$$

onde t é usado para representar o tempo e f_s a frequência do sinal. Essas ondas senoidais são muito bem localizadas na frequência, mas não no tempo, pois seus suportes são de comprimento infinito. Isso é uma consequência da periodicidade das funções base (CASTILHO, et al., 2012).

Do contexto da análise de sinais, a Transformada de Fourier (FT) analisa os conteúdos frequências de um sinal onde não se tem informações sobre quais momentos essas frequências ocorrem (OLIVEIRA. 2007). Dessa forma, caracterizar frequências instantâneas de um sinal no sentido de Fourier, mesmo em casos simples, requer outra ferramenta matemática.

A transformada janelada de Fourier (WFT, *windowed Fourier Transform*) substitui a transformada de Fourier de ondas senoidais pelo produto de uma senóide com uma janela que é localizada no tempo.

Assim, a WFT é definida por meio de (3.27).

$$WFT(\tau, f_s) = \int_{-\infty}^{+\infty} x(t)g(t - \tau)e^{-j2\pi f_s t} . dt \quad (3.27)$$

onde o sinal $g(t-\tau)$ é a função responsável pelo janelamento centrado em τ , em geral, dado por uma gaussiana.

Apesar da WFT ser capaz de fornecer a informação de quando uma determinada frequência ocorreu no sinal, esta tem abrangência limitada pela resolução do tempo ou pelo tamanho da janela, que será o mesmo para todas as frequências (POLIKAR, 1996).

A Transformada *Wavelet* (*Wavelet Transform* – WT) foi desenvolvida como uma abordagem alternativa à WFT para superar o seu problema de resolução. Esta ferramenta permite que um sinal seja decomposto em diferentes componentes de frequências, possibilitando, assim, o estudo de cada componente separadamente em sua escala correspondente (DINIZ, 2018).

A WT da função $x(t)$ é definida por (3.28).


$$WT(a, b) = \int_{-\infty}^{+\infty} x(t) \psi_{a,b}(t) . dt \quad a > 0 \quad (3.28)$$

onde a é o parâmetro de escala, b é o parâmetro de translação, $x(t)$ é o sinal no tempo e $\psi_{a,b}(t)$ é a função *Wavelet* base, $\psi(t)$, escalada e deslocada conforme a equação (3.29).

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi \left(\frac{t - b}{a} \right) \quad (3.29)$$


A variação do parâmetro a tem o efeito de dilatação (quando $a > 1$) e de contração (quando $0 < a < 1$) da função *Wavelet*. Um exemplo dessa dilatação é apresentado na Figura 16.

Figura 16 - Exemplo de dilatação de uma função *Wavelet*



À medida que b varia, a função $x(t)$ é analisada localmente em torno desse ponto. Um exemplo dessa translação é apresentado na Figura 17.


Figura 17 - Exemplo de translação de uma função *Wavelet*



Uma variação da WT, para uso em séries temporais, é a *Maximal Overlap Discrete Wavelet Transform* – MODWT). A MODWT é uma transformada capaz de decompor uma série temporal em subséries que podem ter amostras adicionadas ao seu final, de modo que o sinal seja representado em bandas de frequência com máxima sobreposição, com diferentes resoluções e, por isso, podem ser utilizadas como variáveis de entrada no modelo de previsão (DINIZ, 2018).

Um processo de decomposição da MODWT em três níveis é ilustrado pela Figura 18, em que o sinal $x(t)$ é decomposto em 8 subséries. Uma das características das subséries resultantes do processo de decomposição é a sua perfeita reconstituição aditiva.

Figura 18 - Processo de decomposição do sinal



Fonte: DINIZ (2018)

3.8 Considerações Finais

Neste capítulo foram apresentados a topologia de um neurônio, as funções de ativação, as arquiteturas de redes neurais, os tipos de treinamentos e ferramentas para análises estatísticas dos dados. Por só ter disponível a série histórica diária dos indicadores de DEC e FEC, e nenhuma outra variável exógena, neste trabalho foram utilizadas somente redes recorrentes de primeira ordem (NAR) de uma camada oculta.

No próximo capítulo será apresentado todo o tratamento de dados, a confecção das redes bem como o treinamento e previsões.

Capítulo 4: Desenvolvimento de modelos e resultados

4.1 Seleção do conjunto de unidades consumidoras a ser estudado

Em 2017, a área de concessão da distribuidora da EDP no Espírito Santo era dividida em 58 conjuntos de unidades consumidoras (ANEEL, 2017b). Para escolha do conjunto a ser estudado, foram obtidos junto à distribuidora a série histórica dos indicadores de DEC e FEC diários destes 58 conjuntos no período de 01/01/2010 à 31/12/2017.

Como objeto de análise desta dissertação, dentre os 58, o conjunto São Mateus foi selecionado considerando que, apesar de atender o limite DEC anual, foi um dos conjuntos que ficou próximo ao limite estabelecido pela ANEEL, conforme mostrado no Quadro 1.

Quadro 1 - Indicadores Anuais 2017 dos conjuntos da EDP ES

CONJUNTO	CLIENTES	DEC APURADO	DEC LIMITE	FEC APURADO	FEC LIMITE
AFONSO CLAUDIO	17.859	19,25	18	11,91	11
ALEGRE	17.982	6,93	11	6,25	9
ALTO LAGE	54.459	3,42	6	2,07	5
ARACRUZ	19.964	9,22	11	6,44	9
BAIXO GUANDU	12.979	9,44	14	5,86	11
BARRA DE SÃO FRANCISCO	16.895	11,33	15	7,15	10
BARRA DO SAHY	10.085	17,8	11	10,35	9
BENTO FERREIRA	24.035	2,22	5	0,99	5
BOA ESPERANÇA	5.936	15,52	15	7,21	10
BOM JESUS	12.730	8,23	14	5,2	9
CACHOEIRO	42.230	7,93	8	5,37	7
CANIVETE	11.402	9,83	15	10,03	10
CARAPINA	74.325	2,11	6	1,57	6
CARIACICA	41.001	6,24	7	3,63	6
CASTELO	11.574	4,13	12	2,74	9
CEASA	115.307	5,18	7	3,94	6
CIVIT	76.364	4,67	6	4,53	6
CONCEICAO BARRA	7.004	10,09	11	4	11

continua

continuação

CONJUNTO	CLIENTES	DEC	DEC	FEC	FEC
		APURADO	LIMITE	APURADO	LIMITE
ECOPORANGA	9.361	9,59	14	3,79	10
FRUTEIRAS	18.707	20,02	21	11,06	13
FUNDAO	6.685	18,21	18	9,06	11
GOIABEIRAS	31.892	1,24	5	0,87	5
GUACUI	19.093	8,78	13	5,64	11
GUARAPARI	77.813	7,94	9	4,51	8
IBES	110.264	3,31	6	2,11	5
ITAPEMIRIM	32.990	14,43	13	7,31	9
ITAPOÃ	37.390	2,3	5	1,39	5
ITARANA	16.785	19,28	18	11,09	12
IÚNA	28.765	10,79	12	6,42	9
JAGUARE	11.317	14,37	14	7,23	11
JOAO NEIVA	15.837	17,12	15	8,79	10
JUNCADO	6.639	18,46	17	9,58	10
JURAMA	2.381	17,37	14	5,4	11
LINHARES	51.018	9,98	12	5,74	9
MANGUINHOS	38.076	3,26	6	2,62	6
MANTENOPOLIS	6.371	14,21	15	5,9	10
MARECHAL FLORIANO	22.682	25,66	17	16,73	11
MARMORE	13.199	11,07	8	8,27	7
MIMOSO DO SUL	16.806	12,7	17	6,42	10
MONTANHA	15.917	12,48	15	5,06	10
MUNIZ FREIRE	7.592	12,18	12	7,6	9
NOVA AIMORÉS	4.048	13,59	17	5,73	10
NOVA VENECIA	21.590	10,88	16	6,3	10
PAULISTA	2.258	12,22	18	3,97	11
PEDRO CANARIO	10.712	18,95	15	14,13	10
PINHEIROS	10.870	13,52	15	7,97	10
PIUMA	33.767	7,27	11	3,73	9

continua

conclusão

CONJUNTO	CLIENTES	DEC APURADO	DEC LIMITE	FEC APURADO	FEC LIMITE
PRAIA	79.188	3,13	5	2,9	5
RIO BANANAL	10.787	21,74	22	7,53	11
SANTA MARIA DE JETIBÁ	15.763	23,18	20	12,68	12
SANTA TERESA	9.267	16,72	20	7,76	12
SAO MATEUS	44.879	10,59	11	7,4	10
SERRA SEDE	28.022	11,02	6	6,67	6
SUIÇA	3.891	45,02	20	29,29	13
TRES BARRAS	5.530	14,75	18	6,8	11
VENDA NOVA	20.441	21,06	19	11,02	11

Fonte: ANEEL (2018)

4.2 Metodologia

Para o desenvolvimento deste estudo, foram utilizados os dados diários de DEC e FEC oriundos do conjunto São Mateus da EDP Espírito Santo, localizado no norte do Espírito Santo, referentes ao período de 01/01/2010 a 31/12/2017. Para melhoria no desempenho da rede neural, os dados serão tratados com relação aos seus *outliers*, definidos em 4.3.2, além de normalizados, interpolados e aplicada a MODWT.

Foram coletados também os dados de precipitação pluviométrica, equipes e DEC e FEC diários das 10 principais causas de interrupção com o objetivo de se utilizar uma rede recorrente de segunda ordem (NARX). Porém, os resultados de previsão com a utilização dessa topologia de rede e destes dados tiveram um erro elevado, logo, foram descartados.

Todos os dados coletados foram tratados para a correção de *outliers*. O atraso e a interpolação foram variados com intuito de se obter o melhor desempenho da rede. A quantidade de neurônios na camada oculta será variada de 5 a 50, incrementando 5 neurônios a cada teste, variou-se o *delay* de 2 a 5, incrementando uma unidade a cada teste, e o número de interpolações foi variado de 3 a 6, com incremento de uma unidade. Para cada rede, calculou-se o erro percentual após 3 execuções consecutivas utilizando o algoritmo de aprendizagem Levenberg-Marquardt. A quantidade de neurônios da camada oculta, *delay* e interpolação foi a da rede que apresentou menor erro percentual em sua previsão.


4.3 Tratamento dos dados

Para melhorar o desempenho do modelo de previsão utilizou-se técnicas de tratamento dos dados conforme mostra o diagrama da Figura 19. Cada etapa será descrita nas próximas subseções.

4.3.1 Segmentação semanal

É comum aparecer em séries temporais alguns componentes como tendência, sazonalidade ou um comportamento cíclico. Através de um conhecimento prévio de operação, sabe-se que o perfil de carga da rede elétrica nos fins de semana é diferente para os dias úteis, por exemplo. Dessa maneira, os dados diários de DEC e FEC foram separados em dias da semana e estudados separadamente, criando-se assim uma série temporal para cada dia da semana.

Figura 19 - Diagrama do tratamento de dados realizado



Fonte: Produção do próprio autor.

4.3.2 Tratamento de *Outliers*

Séries temporais possibilitam o estudo de fenômenos complexos, que estão sujeitos a eventos inesperados ou mesmo incontrolláveis. Esses eventos podem originar observações errôneas que, de alguma forma, são inconsistentes com as demais observações da série (MELO; CASTRO, 2013). Estas observações atípicas são denominadas de *outliers* na literatura.

Os *outliers* podem surgir por diversas razões, seja devido a erros grosseiros ou a mudanças na série. Porém, há dados que apresentam naturalmente pontos *outliers*.


Nos dados de DEC e FEC do conjunto São Mateus foi avaliada a presença de *outliers* que influenciam diretamente a homogeneidade das séries, por isso, foram tratados de maneira a torná-los consistentes. Para a identificação dos *outliers*, foram selecionados apenas os dados que estivessem dentro do intervalo $[0; \sigma]$, onde o desvio padrão σ é calculado por (4.1) e (4.2).

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.1)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.2)$$


Calculado e fixado o desvio padrão, as amostras que estivessem fora do intervalo eram eliminadas e depois interpoladas por meio da função *PCHIP* (Polinômio interpolador de hermite cúbica por partes) do *Matlab*. A Figura 20 apresenta um exemplo de tratamento de *outliers* da variável DEC, na qual é possível observar a amplitude do sinal original, do sinal sem *outliers* e dos *outliers* encontrados na amostra em função do número da amostra.

Figura 20 - Resultado do método de tratamento de *outliers* adotado



Fonte: Produção do próprio autor.

A Figura 21 apresenta com mais detalhes o processo de detecção de *outlier* e de interpolação cúbica. O círculo preto é considerado um valor atípico do sinal. A série em azul é o resultado do sinal após a eliminação do outlier e interpolação do ponto identificado.

Figura 21 - Identificação de amostras contendo *outliers*


Fonte: Produção do próprio autor.

4.3.3 Raiz quadrada e Oscilação dos dados

A função de ativação dos neurônios de uma rede neural é responsável por limitar a amplitude de saída de um neurônio e a sua escolha define como devem ser os dados de entrada. A função de ativação do tipo tangente hiperbólica, utilizada neste trabalho, atua no intervalo fechado $[-1, +1]$, ou seja, para valores positivos e negativos.

Uma das características dos dados de DEC e FEC é que eles possuem apenas valores positivos. Porém, para que eles funcionem bem com a função de ativação do tipo tangente hiperbólica, os dados devem possuir tantos valores positivos quanto negativos. Logo, como solução, os sinais das amostras foram alterados entre positivo e negativo. Além disso, aplicou-se a raiz quadrada em todos os dados de forma que quando for feito o retorno para o valor original, independentemente do valor que for previsto, o resultado seja positivo. Na Figura 22 é possível observar o sinal sem *outliers* e o sinal com a aplicação da raiz quadrada e com oscilação de 5 amostras, ou seja, para cada cinco valores positivos, cinco serão negativos.

Figura 22 - Resultado do método de tratamento de dados para melhorar o desempenho da função de ativação.




Fonte: Produção do próprio autor.

4.3.4 Transformada *Wavelet*


Foi implementada a decomposição MODWT com 8 níveis no Matlab, ou seja, em 8 subséries, conforme ilustrado na Figura 23. Nota-se, que a subsérie de nível 1, denominada subsérie de alta frequência, possui grande amplitude, ou seja, uma quantidade de informação relevante assim como a subsérie de nível 2, denominada subsérie de média frequência. Diferentemente das subséries 1 e 2, as subséries de 3 a 8 possuem pouca quantidade de informação e foram somadas para compor a subsérie de baixa frequência, conforme ilustra a Figura 24.

Figura 23 - MODWT: Série decomposta em 8 subséries



Fonte: Produção do próprio autor.

Figura 24 - Sinal de baixa, média e alta frequência a partir da MODWT.




Fonte: Produção do próprio autor.

4.3.5 Normalização

Como as entradas da rede neural apresentam naturezas diferentes, foi necessário que os seus valores fossem normalizados para evitar que os neurônios da camada oculta com funções de ativação tangente hiperbólica, utilizadas neste trabalho, não operem na região de saturação (GAMBOGI, 2013). A normalização dos dados não deixa que a rede tenha uma maior consideração pelos valores de grande magnitude, confundindo o aprendizado da rede. Dessa forma, as técnicas de normalização eliminam esse problema, convertendo os dados para intervalos bem definidos (SEVERO, 2010). Logo, para tornar o treinamento mais efetivo e rápido, os dados foram normalizados de modo que se tenha média zero e desvio padrão igual a um. A Figura 25 mostra a normalização dos dados de baixa, média e alta frequências.

Figura 25 - Normalização dos dados de baixa, média e alta frequência




Fonte: Produção do próprio autor.

4.3.6 Interpolação

A capacidade de aprender, associada a uma rede neural, é uma das mais importantes qualidades destas estruturas. Para conduzir a uma melhoria no desempenho da rede neural, os dados podem ser interpolados de forma a tornar a curva mais suave e acrescentar mais informações. A interpolação dos dados de baixa, média e alta frequências foi realizada a partir da função *spline* do Matlab, que retorna um vetor de valores interpolados de tamanho pré-definido correspondentes aos pontos de seu entorno. A Figura 26 apresenta um exemplo de interpolação de ordem 3 para um pequeno grupo de amostras de baixa, média e alta frequências. A curva azul representa o sinal original e a curva vermelha, o sinal com os valores interpolados.


Figura 26 - Interpolação de dados utilizando a função *spline* do Matlab



Fonte: Produção do próprio autor.

A Figura 27 apresenta um exemplo de interpolação para um grupo de amostras maior, com $i = 3$. A curva azul representa o sinal original e a curva vermelha, o sinal com os valores interpolados. É possível observar que, com a inserção dos pontos de interpolação, a curva se torna mais suave, o que melhora o aprendizado da rede neural.

Figura 27 - Interpolação dos dados



Fonte: Produção do próprio autor.

4.4 Treinamento e Previsão da Rede Neural

Com os dados de entrada (série semanal de DEC e FEC) tratados, foi desenvolvido um código na plataforma *Matlab* para treinamento da RNA para estimação dos indicadores DEC e FEC. Foram utilizadas três configurações de redes NAR para fazer a previsão de cada uma das 3 subséries (baixa, média e alta frequências). Para obter a previsão do sinal original, basta somar as previsões de cada subsérie.

Na etapa de treinamento, são fornecidos dois conjuntos de dados: os valores de entrada e os valores que representam a saída esperada para tais entradas. Foram utilizadas redes recorrentes (NAR) que possuem uma camada de entrada, uma camada oculta e uma camada de saída. As camadas de entrada e de saída possuem apenas um neurônio. O algoritmo de treinamento utilizado é o Levenberg-Marquardt e a função de ativação é a função tangente hiperbólica sigmoidal (tansig).

O *script* criado no *software Matlab* se propõe a encontrar a melhor configuração das redes neurais para cada subsérie, a partir da variação dos valores de interpolação, *delay* e do número de neurônios da camada oculta. A quantidade de neurônios na camada oculta foi variada de 5 a 50, incrementando 5 neurônios a cada teste, variou-se o *delay* de 2 a 5, incrementando uma unidade a cada teste e o número de interpolações de 3 a 6, com incremento de uma unidade. Utilizou-se essas variações, pois em treinamentos prévios notou-se que os erros eram menores nessas faixas.

O código cria, treina e testa 3 (três) redes para cada combinação de quantidade de neurônios na camada oculta, *delay* e interpolação. Foi adotado 70% dos dados para treinamento da RNA, 15% para teste e 15% para validação.

Na etapa de previsão é fornecida somente a entrada para a rede. A saída gerada pela rede é, então, comparada com a saída esperada. O erro de previsão da rede neural é calculado por (4.3).

$$Erro(\%) = \frac{Saída_{gerada} - Saída_{esperada}}{Saída_{esperada}} \times 100 \quad (4.3)$$

Com base no erro calculado é selecionada a melhor configuração para cada subsérie.

4.5 Previsão dos Indicadores de Continuidade

Esta seção apresenta os resultados da previsão dos indicadores de continuidade Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e Frequência Equivalente de Interrupção por Unidade Consumidora (FEC) a partir da utilização das RNA.


Conforme descrito anteriormente, a previsão dos indicadores é realizada para os sinais de baixa, média e alta frequências que foram obtidos durante o processo de tratamento de dados. Então, para cada previsão, são utilizadas três configurações de redes NAR com diferentes parâmetros.

4.5.1 Resultados Individuais de Previsão do Indicador DEC

Para avaliação da previsão do indicador DEC será exemplificado o impacto da presença de *outliers* na série temporal. Foram selecionados resultados da previsão de um dia de domingo e de uma segunda-feira de modo a caracterizar o comportamento de um final de semana e de um dia de semana.


As Figura 28 e 29 apresentam a amplitude dos sinais de entrada original e sem *outliers* do DEC dos dias 10 e 11 de janeiro de 2016, respectivamente em função do número da amostra. Serão comparados os resultados obtidos para as duas entradas: sinal original e sinal sem *outliers*.

Figura 28 - Sinal de entrada original e sem *outliers* para previsão do DEC do dia 10 de janeiro de 2016



Fonte: Produção do próprio autor.

Figura 29 - Sinal de entrada original e sem *outliers* para previsão do DEC do dia 11 de janeiro de 2016



Fonte: Produção do próprio autor.

a) Previsão do Indicador DEC utilizando o sinal original como entrada

Inicialmente, foram desenvolvidos modelos de previsão do indicador DEC utilizando como entrada o sinal original, sem o tratamento de *outliers*.

Na busca pela melhor topologia, as previsões do DEC para os dias 10 e 11 de janeiro de 2016 utilizam como sinal de entrada os sinais originais apresentados nas Figuras 28 e 29, respectivamente. Os resultados são apresentados nas Tabelas 1 e 2.

Tabela 1 - Melhor configuração de rede do indicador DEC na previsão do dia 10 de jan. 2016, utilizando o sinal sem tratamento de *outliers* como entrada

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	15	3	2	0,1358
Média Frequência	NAR	35	3	3	-0,3709
Alta Frequência	NAR	25	4	2	591,0354

Fonte: Produção do próprio autor.

Tabela 2 - Melhor configuração de rede do indicador DEC na previsão do dia 11 de jan. 2016, utilizando o sinal sem tratamento de *outliers* como entrada

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	5	3	2	-0,6767
Média Frequência	NAR	10	3	2	0,4949
Alta Frequência	NAR	15	4	2	-0,1510


Fonte: Produção do próprio autor.

As Figuras 30, 31 e 32 apresentam a previsão para as subséries de baixa, média e alta frequências, respectivamente, na previsão do dia 10 de janeiro de 2016. As curvas em azul

representam o sinal original de entrada interpolado, as curvas em verde os dados de treinamento da RNA e as curvas em vermelho o sinal previsto interpolado.


Pela análise dos gráficos apresentados nas Figuras 30, 31 e 32, pode-se constatar que a rede aprendeu com os valores fornecidos na entrada. Porém, só foi capaz de prever com pouco erro os valores esperados na saída para a baixa e para a média frequências. Após a soma de todas as componentes, o erro final obtido para a predição do DEC no dia 10 de janeiro de 2016 foi de 83,20%.

Figura 30 - Previsão da subsérie de baixa frequência (BF) do indicador DEC com Horizonte de Previsão (HP) = 1 do dia 10 de janeiro de 2016, utilizando o sinal sem tratamento de *outliers* como entrada




Fonte: Produção do próprio autor.

Figura 31 - Previsão da subsérie de média frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal sem tratamento de *outliers* como entrada



Fonte: Produção do próprio autor.

Figura 32 - Previsão da subsérie de alta frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal sem tratamento de *outliers* como entrada




Fonte: Produção do próprio autor.

As Figuras 33, 34 e 35 apresentam a previsão para as subséries de baixa, média e alta frequências, respectivamente, na previsão do dia 11 de janeiro de 2016. As curvas em azul representam o sinal de entrada original interpolado, as curvas em verde os dados de treinamento da RNA e as curvas em vermelho o sinal previsto interpolado.


Pela análise dos gráficos apresentados nas Figuras 33, 34 e 35, pode-se constatar que a rede foi capaz de aprender com os valores fornecidos na entrada e predizer, com pouco erro, os valores esperados na saída. Após a soma de todas as componentes, o erro final obtido para a predição do DEC no dia 11 de janeiro de 2016 foi de 1,57%.

Figura 33 - Previsão da subsérie de baixa frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

Figura 34 - Previsão da subsérie de média frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.

Figura 35 - Previsão da subsérie de alta frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.

b) Previsão do Indicador DEC utilizando o sinal com tratamento de *outliers* como entrada

Nesta etapa, foram desenvolvidos modelos de previsão do indicador DEC, utilizando como entrada o sinal com tratamento de *outliers* descrito na subseção 4.3.2.

Na busca pela melhor topologia, as previsões do DEC para os dias 10 e 11 de janeiro de 2016 utilizam como sinais de entrada os sinais com tratamento de *outliers* apresentados nas Figuras 28 e 29, respectivamente. Os resultados são apresentados nas Tabelas 3 e 4.

Tabela 3 - Melhor configuração de rede do indicador DEC na previsão do dia 10 de jan. 2016, utilizando o sinal com tratamento de *outliers* como entrada

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	5	3	2	-0,0642
Média Frequência	NAR	45	6	3	-0,2400
Alta Frequência	NAR	5	3	3	0,5878

Fonte: Produção do próprio autor.


Tabela 4 - Melhor configuração de rede do indicador DEC na previsão do dia 11 de jan. 2016, utilizando o sinal com tratamento de *outliers* como entrada

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	5	3	2	-0,0663
Média Frequência	NAR	45	3	3	0,8644
Alta Frequência	NAR	15	3	2	-0,5300

Fonte: Produção do próprio autor.


As Figuras 36, 37 e 38 apresentam a previsão para as subséries de baixa, média e alta frequências, respectivamente, na previsão do dia 10 de janeiro de 2016. As curvas em azul representam o sinal original interpolado, em verde os dados de treinamento da RNA e em vermelho o sinal previsto interpolado. Pela análise dos gráficos das Figuras 36, 37 e 38, pode-se constatar que a rede foi capaz de aprender com os valores fornecidos na entrada e predizer, com pouco erro, os valores esperados na saída. O erro final obtido para a predição do DEC no dia 10 de janeiro de 2016 foi de 0,65%.

Figura 36 - Previsão da subsérie de baixa frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal com tratamento de *outliers* como entrada




Fonte: Produção do próprio autor.

Figura 37 - Previsão da subsérie de média frequência do indicador DEC do dia 10 de janeiro de 2016, utilizando o sinal com tratamento de *outliers* como entrada



Fonte: Produção do próprio autor.

Figura 38 - Previsão da subsérie de alta frequência do indicador DEC do dia 10 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

As Figuras 39, 40 e 41 apresentam a previsão para as subséries de baixa, média e alta frequência, respectivamente, na previsão do dia 11 de janeiro de 2016. As curvas em azul representam o sinal original interpolado, as curvas em verde representam os dados de treinamento da RNA e as curvas em vermelho representam o sinal previsto interpolado.


Pela análise dos gráficos apresentados nas Figuras 39, 40 e 41, pode-se constatar que a rede foi capaz de aprender com os valores fornecidos na entrada e predizer com pouco erro os valores esperados na saída. O erro final obtido para a previsão do DEC no dia 11 de janeiro de 2016 foi de 3,45%.

Figura 39 - Previsão da subsérie de baixa frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

Figura 40 - Previsão da subsérie de média frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.

Figura 41 - Previsão da subsérie de alta frequência do indicador DEC do dia 11 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

4.5.2 Resultados Individuais de Previsão do Indicador FEC

Para avaliação da previsão do indicador FEC, será exemplificado o impacto da presença de *outliers* na série temporal. Foram selecionados resultados da previsão de um dia de domingo e de uma segunda-feira, de modo a caracterizar o comportamento de um final de semana e de um dia da semana.


As Figuras 42 e 43 apresentam a amplitude dos sinais de entrada original e sem *outliers* do DEC dos dias 17 e 18 de janeiro de 2016, respectivamente em função do número da amostra. Serão comparados os resultados obtidos para as duas entradas: sinal original e sem *outliers*.

Figura 42 - Sinal de entrada original e sem *outliers* para previsão do FEC do dia 17 de janeiro de 2016



Fonte: Produção do próprio autor.

Figura 43 - Sinal de entrada original e sem *outliers* para previsão do FEC do dia 18 de janeiro de 2016.



Fonte: Produção do próprio autor.

a) Previsão do Indicador FEC utilizando o sinal original como entrada

Foram desenvolvidos modelos de previsão do indicador FEC utilizando como entrada o sinal original, sem o tratamento de *outliers* descrito na subseção 4.3.2.

Na busca pela melhor topologia, as previsões do FEC para os dias 17 e 18 de janeiro de 2016 utilizam como sinal de entrada os sinais originais apresentados nas Figuras 42 e 43, respectivamente. Os resultados são exibidos nas Tabelas 5 e 6.

Tabela 5 - Melhor configuração de rede do indicador FEC na previsão do dia 17 de jan. 2016, utilizando o sinal sem tratamento de *outliers* como entrada

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	5	3	2	-0,3967
Média Frequência	NAR	30	3	2	0,6826
Alta Frequência	NAR	5	4	3	1,3992

Fonte: Produção do próprio autor.


Tabela 6 - Melhor configuração de rede do indicador FEC na previsão do dia 18 de jan. 2016, utilizando o sinal sem tratamento de *outliers* como entrada

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	50	3	3	-0,4376
Média Frequência	NAR	5	3	4	0,2820
Alta Frequência	NAR	10	4	2	-0,4723

Fonte: Produção do próprio autor.


As Figuras 44, 45 e 46 apresentam a previsão para as subséries de baixa, média e alta frequência, respectivamente na previsão do dia 17 de janeiro de 2016, as Figuras 47, 48 e 49 apresentam a previsão para as subséries de baixa, média e alta frequência, respectivamente na previsão do dia 18 de janeiro de 2016. A curva em azul representa o sinal original interpolado, a em verde os dados de treinamento da RNA e a em vermelho o sinal previsto interpolado.

Figura 44 - Previsão da subsérie de baixa frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

Figura 45 - Previsão da subsérie de média frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.


Figura 46 - Previsão da subsérie de alta frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.


Pela análise dos gráficos apresentados nas Figuras 44, 45 e 46, pode-se constatar que a rede neural foi capaz de aprender com os valores fornecidos na entrada e predizer, com pouco erro, os valores esperados na saída. O erro final obtido para a previsão do FEC no dia 17 de janeiro de 2016 foi de 1,07%.

Figura 47 - Previsão da subsérie de baixa frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

Figura 48 - Previsão da subsérie de média frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.

Figura 49 - Previsão da subsérie de alta frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal sem tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.

Pela análise dos gráficos apresentados nas Figuras 47, 48 e 49, pode-se constatar que a rede foi capaz de aprender com os valores fornecidos na entrada e predizer, com pouco erro, os valores esperados na saída. O erro final obtido para a previsão do FEC no dia 18 de janeiro de 2016 foi de 0,91%.

b) Previsão do Indicador FEC utilizando o sinal com tratamento de *outliers* como entrada

Foram desenvolvidos modelos de previsão do indicador FEC utilizando como entrada o sinal com tratamento de *outliers* descrito na subseção 4.3.2.

Na busca pela melhor topologia, as previsões do FEC para os dias 17 e 18 de janeiro de 2016 utilizam como sinal de entrada o sinal com tratamento de *outliers* apresentados nas Figuras 42 e 43, respectivamente. Os resultados são exibidos nas Tabelas 7 e 8.

Tabela 7 - Melhor configuração de rede do indicador FEC na previsão do dia 17 de jan. 2016, utilizando o sinal com tratamento de *outliers* como entrada

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	5	3	2	-0,1587
Média Frequência	NAR	10	3	2	0,7971
Alta Frequência	NAR	40	4	3	0,7433

Fonte: Produção do próprio autor.


Tabela 8 - Melhor configuração de do indicador FEC na previsão do dia 18 de jan. 2016 utilizando o sinal com tratamento de *outliers* como entrada.

Subsérie	Topologia	Tamanho da camada oculta	Interpolação	Delay	Erro (%)
Baixa Frequência	NAR	30	3	2	-0,5619
Média Frequência	NAR	30	3	3	0,0725
Alta Frequência	NAR	10	3	3	-0,9471

Fonte: Produção do próprio autor.


Pela análise dos gráficos apresentados nas Figuras 50, 51 e 52, pode-se constatar que a rede foi capaz de aprender com os valores fornecidos na entrada e prever, com pouco erro, os valores esperados na saída. O erro final obtido para a previsão do FEC no dia 17 de janeiro de 2016 foi de 1,0697 %.

Figura 50 - Previsão da subsérie de baixa frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

Figura 51 - Previsão da subsérie de média frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.


Figura 52 - Previsão da subsérie de alta frequência do indicador FEC do dia 17 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.


As Figuras 53, 54 e 55 apresentam a previsão para as subséries de baixa, média e alta frequência, respectivamente, na previsão do dia 18 de janeiro de 2016 do FEC.

Figura 53 - Previsão da subsérie de baixa frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.




Fonte: Produção do próprio autor.

Figura 54 - Previsão da subsérie de média frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.

Figura 55 - Previsão da subsérie de alta frequência do indicador FEC do dia 18 de janeiro de 2016 utilizando o sinal com tratamento de *outliers* como entrada.



Fonte: Produção do próprio autor.

Pela análise dos gráficos apresentados nas Figuras 53, 54 e 55, pode-se constatar que a rede foi capaz de aprender com os valores fornecidos na entrada e predizer com pouco erro os valores esperados na saída. O erro final obtido para a previsão do FEC no dia 18 de janeiro de 2016 foi de 0,90%.

4.5.3 Resultados de Previsão Mensais do Indicador DEC

A seguir, a Tabelas 9 apresenta os resultados obtidos na previsão do indicador DEC para todos os dias do mês de janeiro de 2016. Nota-se que grande parte dos modelos foram capazes de predizer, com pouco erro, os valores esperados na saída, com exceção dos dias 9, 14 e 20 de janeiro, que tiveram o erro total de previsão maior que 100%.

Tabela 9 - Melhor configuração de rede encontrada para cada subsérie do indicador DEC na previsão dos dias de jan. 2016.

DIA	Subsérie	Tamanho da Camada Oculta	Interpolação	Delay	Erro(%)	Erro Total de previsão (%)
1	Baixa Frequência	45	3	5	0,3774	40,1559
	Média Frequência	35	3	3	-0,142	
	Alta Frequência	50	3	3	-96,8528	
2	Baixa Frequência	5	3	2	0,112	0,6763
	Média Frequência	40	3	3	23,7549	
	Alta Frequência	40	6	2	12,802	
3	Baixa Frequência	15	3	2	-0,582	2,9972
	Média Frequência	45	3	2	-0,3278	
	Alta Frequência	50	5	5	2,3799	
4	Baixa Frequência	5	3	2	-0,4271	5,2794
	Média Frequência	40	3	4	0,3855	
	Alta Frequência	30	5	3	-8,4401	
5	Baixa Frequência	5	3	2	0,057	27,483
	Média Frequência	35	3	5	-19,1357	
	Alta Frequência	35	5	4	-41,8826	
6	Baixa Frequência	20	3	2	-0,7858	0,5826
	Média Frequência	15	3	2	0,236	
	Alta Frequência	20	6	5	9,2735	
7	Baixa Frequência	5	3	2	0,0933	4,354
	Média Frequência	40	3	3	-115,665	
	Alta Frequência	15	3	3	0,206	
8	Baixa Frequência	45	3	4	0,8695	7,748
	Média Frequência	40	6	5	-0,3846	
	Alta Frequência	40	3	5	-0,2402	
9	Baixa Frequência	10	3	2	0,7482	372,9451
	Média Frequência	40	4	2	-8,3987	
	Alta Frequência	35	5	2	-46,8043	
10	Baixa Frequência	5	3	2	-0,0642	0,653
	Média Frequência	45	6	3	-0,24	
	Alta Frequência	5	3	3	0,5878	
11	Baixa Frequência	5	3	2	-0,0663	3,4499
	Média Frequência	45	3	3	0,8644	
	Alta Frequência	15	3	2	-0,53	
12	Baixa Frequência	50	3	2	0,8158	2,3434
	Média Frequência	5	6	3	-0,7064	
	Alta Frequência	50	6	4	1,4591	
13	Baixa Frequência	20	3	2	-0,176	19,146
	Média Frequência	50	3	2	0,0192	
	Alta Frequência	45	5	4	27,4527	
14	Baixa Frequência	10	3	2	0,2079	501,4258
	Média Frequência	30	3	3	0,1629	
	Alta Frequência	45	4	5	-34,9285	
15	Baixa Frequência	50	3	2	0,442	7,9303
	Média Frequência	5	3	4	-0,4099	
	Alta Frequência	45	3	3	-0,7488	

continua


conclusão

DIA	Subsérie	Tamanho da Camada Oculta	Interpolação	Delay	Erro(%)	Erro Total de previsão (%)
16	Baixa Frequência	25	3	3	0,7314	23,1875
	Média Frequência	10	3	3	-19,6771	
	Alta Frequência	35	3	2	-0,4238	
17	Baixa Frequência	10	3	2	-0,4518	6,52
	Média Frequência	25	5	2	7,7358	
	Alta Frequência	50	5	3	2,2454	
18	Baixa Frequência	5	3	2	-0,2104	1,8423
	Média Frequência	50	3	3	0,8849	
	Alta Frequência	40	3	2	-0,2368	
19	Baixa Frequência	5	3	2	0,0807	0,1798
	Média Frequência	45	3	4	-0,2672	
	Alta Frequência	45	3	4	0,0094	
20	Baixa Frequência	5	3	2	-0,8176	108,9337
	Média Frequência	5	3	4	0,2193	
	Alta Frequência	35	3	5	-61,1219	
21	Baixa Frequência	5	3	2	0,4712	2,4656
	Média Frequência	40	3	5	0,7037	
	Alta Frequência	40	4	5	-0,709	
22	Baixa Frequência	10	3	2	0,9575	0,2276
	Média Frequência	35	3	2	-0,602	
	Alta Frequência	5	3	2	0,2838	
23	Baixa Frequência	5	3	2	0,8181	0,4815
	Média Frequência	50	3	2	-0,317	
	Alta Frequência	45	3	4	0,2928	
24	Baixa Frequência	50	3	4	-0,3567	0,0698
	Média Frequência	10	3	2	0,0776	
	Alta Frequência	30	3	4	-0,1057	
25	Baixa Frequência	5	3	2	-0,1388	35,2118
	Média Frequência	25	3	2	5,5121	
	Alta Frequência	45	6	5	-6,2549	
26	Baixa Frequência	10	6	3	0,383	98,5384
	Média Frequência	50	4	4	48,5083	
	Alta Frequência	40	3	2	-86,9911	
27	Baixa Frequência	15	3	2	-0,6658	36,1142
	Média Frequência	45	4	5	0,9442	
	Alta Frequência	50	6	5	-143,713	
28	Baixa Frequência	35	3	4	0,3107	5,9117
	Média Frequência	45	3	5	19,7827	
	Alta Frequência	40	3	4	-13,0211	
29	Baixa Frequência	10	3	2	0,4439	0,6327
	Média Frequência	25	3	2	-0,4028	
	Alta Frequência	5	4	5	0,6555	
30	Baixa Frequência	10	3	2	0,7193	54,181
	Média Frequência	45	3	3	-22,7948	
	Alta Frequência	50	4	3	-8,7422	
31	Baixa Frequência	10	3	2	-0,1876	1,4644
	Média Frequência	15	3	2	0,1706	
	Alta Frequência	25	3	2	-0,8617	

Fonte: Produção do próprio autor.

A Figura 56 apresenta o diagrama de extremos e quartis (*boxplot*) do erro absoluto percentual para o indicador DEC realizado a partir dos dados apresentados na Tabela 9. O *boxplot* é um gráfico utilizado para avaliar a distribuição empírica dos dados e é formado pelo primeiro e terceiro quartil e pela mediana. Os pontos fora das hastes inferior e superior são considerados valores discrepantes (*outliers*). Os resultados revelam que o sinal de baixa frequência obteve o melhor resultado, com o erro percentual sempre menor que 1%, em módulo. Na média frequência houve a presença de um ponto atípico, com erro de -115,67%. Porém a maioria dos dias obteve como resultado erro máximo de 20%, em módulo. Por sua vez, os resultados obtidos a partir do treinamento da subsérie de alta frequência revelaram pontos com erros mais altos.


Figura 56 – *Boxplot* do erro percentual do DEC para os sinais de: (a) baixa frequência, (b) média frequência, (c) alta frequência.



Fonte: Produção do próprio autor.


As Figuras 57 e 58 apresentam os gráficos com os resultados de previsão do indicador DEC para os meses de janeiro e fevereiro de 2016, respectivamente. A curva cinza representa o indicador DEC real e a curva vermelha o DEC previsto. A curva vermelha com ponto representa o indicador diário previsto pela rede neural e a curva cinza com ponto representa o indicador diário ocorrido.

Figura 57 – Resultados de previsão do indicador DEC para o mês de janeiro de 2016.



Fonte: Produção do próprio autor.

Figura 58 - Resultados de previsão do indicador DEC para o mês de fevereiro de 2016.



Fonte: Produção do próprio autor.

A Tabela 10 apresenta os valores mensais do indicador DEC para os meses de janeiro e fevereiro de 2016 real, previsto a partir do modelo com RNA e os erros mensais absolutos de previsão calculados por (4.3).

Tabela 10 - DEC real e previsto a partir do modelo com RNA.

	DEC REAL	DEC PREVISTO RNA	ERRO FINAL (%) DEC PREVISTO RNA
JAN. 2016	0,0175	0,0178	1,7143
FEV. 2016	0,0115	0,0116	0,8696

Fonte: Produção do próprio autor.

4.5.3 Resultados de Previsão Mensal do Indicador FEC

A seguir, a Tabela 11 apresenta os resultados obtidos na previsão do indicador FEC para todos os dias do mês de janeiro de 2016. Nota-se que grande parte dos modelos foram capazes de prever, com pouco erro, os valores esperados na saída, com exceção dos dias 26 e 28 de janeiro, que tiveram o erro total de previsão maior que 100%. O erro desses dias foi impactado diretamente pelo erro da previsão de alta frequência.

Tabela 11 - Melhor configuração de rede encontrada para cada subsérie do indicador FEC na previsão dos dias de jan. 2016.

DIA	Subsérie	Tamanho da Camada Oculta	Interpolação	Delay	Erro(%)	Erro Total de previsão (%)
1	Baixa Frequência	5	3	2	0,8395	1,6661
	Média Frequência	50	3	4	-0,199	
	Alta Frequência	45	4	2	-0,2669	
2	Baixa Frequência	5	3	2	0,0714	6,067
	Média Frequência	45	6	2	-4,8881	
	Alta Frequência	25	4	5	-33,0193	
3	Baixa Frequência	5	3	2	0,312	0,6395
	Média Frequência	15	3	4	-0,4657	
	Alta Frequência	50	3	5	5,5087	
4	Baixa Frequência	35	3	2	-0,5884	11,153
	Média Frequência	5	3	4	0,4895	
	Alta Frequência	50	5	3	-5,5079	
5	Baixa Frequência	10	3	2	0,5845	87,6138
	Média Frequência	50	5	3	-0,2481	
	Alta Frequência	45	3	5	-69,6556	
6	Baixa Frequência	30	3	5	0,6846	0,956
	Média Frequência	15	5	5	0,9997	
	Alta Frequência	45	6	4	-0,4869	
7	Baixa Frequência	20	3	2	0,4405	0,2356
	Média Frequência	40	3	3	-12,8434	
	Alta Frequência	20	3	5	0,8107	
8	Baixa Frequência	5	3	2	0,01	21,9893
	Média Frequência	40	3	4	-0,3946	
	Alta Frequência	5	3	2	-0,6632	
9	Baixa Frequência	5	3	2	0,6698	4,0853
	Média Frequência	5	3	5	-0,0289	
	Alta Frequência	35	4	3	-0,0729	
10	Baixa Frequência	5	3	2	0,778	46,2129
	Média Frequência	30	3	4	0,1803	
	Alta Frequência	50	6	4	-348,828	
11	Baixa Frequência	10	3	2	-0,016	4,1756
	Média Frequência	5	3	3	0,6187	
	Alta Frequência	25	3	2	-0,8085	
12	Baixa Frequência	10	3	2	-0,5384	1,2107
	Média Frequência	15	3	3	-0,5843	
	Alta Frequência	30	3	2	-48,1372	
13	Baixa Frequência	15	3	2	-0,2541	5,0594
	Média Frequência	40	3	3	0,9347	
	Alta Frequência	45	4	5	-36,6302	
14	Baixa Frequência	15	3	2	0,6971	83,3908
	Média Frequência	15	3	2	0,5919	
	Alta Frequência	45	4	4	-11,458	
15	Baixa Frequência	5	3	2	0,3827	24,0806
	Média Frequência	10	3	2	-0,8783	
	Alta Frequência	30	4	5	12,6277	

continua


conclusão

DIA	Subsérie	Tamanho da Camada Oculta	Interpolação	Delay	Erro(%)	Erro Total de previsão (%)
16	Baixa Frequência	5	3	2	0,3152	12,313
	Média Frequência	45	3	5	-0,5199	
	Alta Frequência	20	3	5	-0,6268	
17	Baixa Frequência	5	3	2	-0,1587	0,9175
	Média Frequência	10	3	2	0,7971	
	Alta Frequência	40	4	3	0,7433	
18	Baixa Frequência	30	3	2	-0,5619	0,59
	Média Frequência	30	3	3	0,0725	
	Alta Frequência	10	3	3	-0,9471	
19	Baixa Frequência	30	3	2	-0,9924	0,3882
	Média Frequência	40	6	2	-1,7231	
	Alta Frequência	25	4	2	0,084	
20	Baixa Frequência	40	3	2	-0,3003	19,9611
	Média Frequência	5	5	2	0,3976	
	Alta Frequência	50	3	4	-3,7872	
21	Baixa Frequência	25	3	2	0,5274	64,9949
	Média Frequência	30	3	4	-2,7189	
	Alta Frequência	50	3	3	90,7985	
22	Baixa Frequência	5	5	2	0,791	0,8906
	Média Frequência	35	3	5	-0,4142	
	Alta Frequência	5	3	2	0,9397	
23	Baixa Frequência	15	3	2	0,8611	0,3099
	Média Frequência	20	5	5	-0,3716	
	Alta Frequência	25	3	3	0,1395	
24	Baixa Frequência	20	3	2	-0,3697	0,5845
	Média Frequência	15	3	3	0,5813	
	Alta Frequência	30	3	4	-0,1147	
25	Baixa Frequência	5	3	2	-0,8005	12,7411
	Média Frequência	45	6	3	-96,0337	
	Alta Frequência	20	4	2	-0,9365	
26	Baixa Frequência	5	3	2	-0,3633	210,6183
	Média Frequência	50	4	2	0,9017	
	Alta Frequência	50	3	3	-142,972	
27	Baixa Frequência	5	3	2	-0,1881	27,3483
	Média Frequência	10	3	2	0,3735	
	Alta Frequência	50	4	5	277,1287	
28	Baixa Frequência	15	6	2	0,985	184,8392
	Média Frequência	45	3	4	-0,9862	
	Alta Frequência	25	3	3	-294,037	
29	Baixa Frequência	50	3	4	0,3174	0,7859
	Média Frequência	5	3	2	-0,0601	
	Alta Frequência	35	6	5	1,7581	
30	Baixa Frequência	5	3	5	0,9615	73,8619
	Média Frequência	35	3	3	-9,698	
	Alta Frequência	30	5	2	-17,55	
31	Baixa Frequência	5	3	2	-0,7702	0,5965
	Média Frequência	5	3	2	0,4209	
	Alta Frequência	20	3	2	-0,3929	

Fonte: Produção do próprio autor.

A Figura 59 exibe o *boxplot* do erro percentual para o indicador FEC realizado a partir dos dados apresentados na Tabela 11. Os resultados revelam que o sinal de baixa frequência obteve o melhor resultado, com o erro percentual sempre menor que 1%, em módulo. Na média frequência houve a presença de um ponto atípico, com erro de -96,337%. Porém a maioria dos dias obteve como resultado erro máximo de 15% em módulo. Por sua vez, os resultados obtidos a partir do treinamento da subsérie de alta frequência revelaram mais pontos atípicos, com erros mais altos.


Figura 59 - *Boxplot* do erro percentual do FEC para os sinais de: (a) baixa frequência, (b) média frequência, (c) alta frequência.



Fonte: Produção do próprio autor.


As Figuras 60 e 61 apresentam os gráficos com os resultados de previsão do indicador FEC para os meses de janeiro e fevereiro de 2016. A curva cinza representa o indicador FEC real e a curva vermelha representa o indicador FEC previsto. A curva cinza representa o indicador FEC real e a curva vermelha representa o indicador FEC previsto. A curva vermelha com ponto representa o indicador diário previsto pela rede neural e a curva cinza com ponto representa o indicador diário ocorrido.

Figura 60 - Resultados de previsão do indicador FEC para o mês de janeiro de 2016



Fonte: Produção do próprio autor.

Figura 61 - Resultados de previsão do indicador FEC para o mês de fevereiro de 2016



Fonte: Produção do próprio autor.

A Tabela 12 apresenta os valores mensais do indicador FEC para os meses de janeiro e fevereiro de 2016 real, previsto a partir do modelo com RNA e os erros de previsão calculados a partir de (4.3).

Tabela 12 - FEC real, previsto pelo método da distribuidora e previsto a partir do modelo com RNA.

	FEC REAL	FEC PREVISTO RNA	ERRO (%) FEC PREVISTO RNA
JAN. 2016	0,0094	0,0087	-7,4468
FEV. 2016	0,0073	0,0065	-10,9589

Fonte: Produção do próprio autor.

4.6 Análise

Para avaliação do método, foram previstos os indicadores de dois meses: janeiro e fevereiro de 2016. Estes meses representam um período crítico para concessionária, pois a rede de distribuição fica mais carregada em função do período de férias e por se tratar da estação do ano em que as temperaturas são mais altas, o que implica em um aumento na carga devido ao uso de condicionadores de ar. Além disso, neste período é quando ocorre a maior precipitação

de chuvas no estado do Espírito Santo submetendo a rede a uma maior agressão climática. Desta forma, como nos meses mais críticos foi possível prever os indicadores de continuidade com baixos erros, pode-se assumir que nos meses em que a operação do sistema é mais estável o modelo terá resultados ainda melhores.

Verificou-se também que, mesmo com a realização dos tratamentos dos dados, a rede neural teve maior dificuldade em prever o FEC do que o DEC, pois o FEC é de natureza mais impulsiva, ou seja, o sinal possui maior variação se comparado ao indicador DEC, imputando assim mais componentes de alta frequência e consequentemente, aumentado a dificuldade de previsão.

Com relação à interpolação, notou-se que se faz necessário um balanço do número de interpolações, pois quanto mais pontos inserimos mais a curva se torna suave facilitando o aprendizado, porém mais distante se torna o ponto de previsão de interesse.

Capítulo 5: Conclusões

Esta dissertação propôs o desenvolvimento de modelos matemáticos baseados em RNA para a previsão dos valores dos indicadores de continuidade DEC e FEC, visando auxiliar a concessionária na realização do planejamento das tarefas de manutenção, buscando a mitigação de violações e realização de compensações.

O tratamento dos dados de entrada dos indicadores de continuidade permitiu que houvesse uma melhora no desempenho das redes neurais. De uma maneira geral, as redes que apresentaram as melhores previsões foram aquelas que utilizaram o tratamento de dados, com o tratamento de *outliers* nos dados de entradas conforme apontado por Araújo (2016).

O desenvolvimento dos modelos trouxe resultados bastante significativos na predição do DEC e do FEC. Os erros totais acumulados na previsão do indicador DEC ao final dos meses de janeiro e de fevereiro de 2016 foram 1,71% e 0,87%, respectivamente. Na previsão do FEC, os erros totais acumulados ao final dos meses de janeiro e de fevereiro de 2016 foram -7,45% e -10,96%, nesta ordem.

Para se obter estes resultados, o tratamento de *outliers*, oscilação do sinal com aplicação da raiz quadrada, a decomposição do sinal em subséries com a transformada *Wavelet* e a normalização do sinal foram de vital importância para o aprendizado da RNA.

Verificou-se que para se obter bons resultados é necessário que a cada dia as redes sejam novamente treinadas para ajuste da quantidade de neurônios, atrasos e interpolação, ou seja, não foi possível estabelecer uma solução única de camadas e neurônios que dê resultados razoáveis em todas as condições e em todos os dias com a topologia de rede adotada. Isso não será um problema, pois por trabalhar com séries temporais distintas para cada dia da semana há um prazo de 6 dias para se construir um novo modelo e realizar a previsão.

Portanto, os objetivos foram alcançados e os resultados obtidos por este trabalho vão permitir que decisões mais adequadas sejam tomadas sobre a execução de ações de manutenção contribuindo assim para a confiabilidade operacional do sistema elétrico.

Para trabalhos futuros, sugere-se melhorar o modelo de identificação da componente de alta frequência da série, utilizar os dados do dia anterior como entrada exógena, utilizar modelos de redes neurais baseadas em aprendizagem profunda para a previsão dos indicadores, testar outras estratégias de condicionamento dos dados baseadas nas características impulsivas das séries e fazer tratamento dos *outliers*, por exemplo, considerando como uma outra série dentro do modelo.

Referências Bibliográficas

ADERALDO, V. P. **Utilização de Redes Neurais Artificiais para Detecção de Anomalia em Redes de Computadores**. 2017. 58f. Trabalho de Conclusão de Curso – Universidade Estadual de Londrina, Londrina, 2017.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST**. 2018a. Disponível em < <http://www.ANEEL.gov.br/prodist> >. Acesso em: 14 mai. 2018.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST, Módulo 8 – Qualidade da Energia Elétrica** – 2018b. Disponível em: <<http://www.ANEEL.gov.br/modulo-8>>. Acesso em: 14 mai. 2018.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. **Compensação pela Transgressão dos Limites de Continuidade**. 2017a. Disponível em: <<http://www.ANEEL.gov.br/indicadores-de-compensacao-de-continuidade>>. Acesso em: 14 mai. 2018.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. **Indicadores de Continuidade**. 2017b. Disponível em: <http://www2.aneel.gov.br/aplicacoes/indicadores_de_qualidade/resultado.cfm>. Acesso em: 18 mai. 2018.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. **Nota Técnica nº 0106/2016-SRD/ANEEL**. 2016.

ARAÚJO, J. A. **Modelo para Predição de Indicadores de Continuidade em um Sistema de Distribuição de Energia Elétrica: uma Aplicação à Gestão de Manutenção com a Perspectiva do uso da Termografia**. 2016. 147f. Dissertação de Mestrado – Universidade Federal da Bahia, Salvador - BA, 2016.

CASTILHO, J. E. *et al.* **Introdução ao Mundo das Wavelets**. 2012. 144 f. Notas em Matemática Aplicada. Sociedade brasileira de Matemática aplicada e Computacional. São Carlos - SP, 2012.

COELHO, J. *et al.* **Reliability Diagnosis of Distribution System under Adverse Weather Conditions**. 2003. 5f. IEEE Bologna Power Tech Conference. Itália, 2003.

DIAS, E. B. **Avaliação de Indicadores de Continuidade e seu Impacto no Planejamento de Sistemas de Distribuição**. 2002. 159f. Dissertação de Mestrado – Universidade de São Paulo, São Paulo, 2002.

DINIZ, A. P. M. **Modelos de Previsão do Conteúdo de Silício no Ferro-Gusa Usando Redes Neurais Artificiais**. 2018. 173f. Dissertação de Mestrado – Universidade Federal do Espírito Santo, Vitória, 2018.

FERNEDA, E. **Redes Neurais e sua Aplicação em Sistemas de Recuperação de Informação**. 2006. 6f. Instituto Brasileiro de Informação em Ciência e Tecnologia – IBICT. Brasília, 2006.

FINOCCHIO, M. A. F. **Noções de Redes Neurais Artificiais**. 2014. 29f. Universidade Tecnologia Federal do Paraná. Cornélio Procópio, 2014.

GAMBOGI, J. A. **Aplicação de Redes Neurais na Tomada de Decisão no Mercado de Ações**. 2013. 78f. Dissertação de Mestrado – Universidade de São Paulo, São Paulo, 2013.

HAYKIN, S. **Neural Networks and Learning Machines**. 3a. ed. Pearson, 2009. 906 p.

JÚNIOR, L. A. Teixeira. *et al.* **Combinação Linear Wavelet Sarima-RNA com Estágios Múltiplos na Previsão de Séries Temporais**. 2016. 13f. XVIII Simpósio de Pesquisa Operacional & Logística da Marinha. São Paulo, 2016.

LAGES, W. F. **Descrição de Sinais Aleatórios**. 2004. 18f. Universidade Federal do Rio Grande do Sul. 2004.

MAGALHÃES, E. F. A. **Modelagem e Simulação de Indicadores de Continuidade: Ferramenta Auxiliar para a Manutenção em Redes de Distribuição de Energia Elétrica**. 2017. 146f. Dissertação de Mestrado – Universidade Federal da Bahia, Salvador, 2017.

MAZUCHELI, J.; ACHCAR, J. A. **Algumas Consideração em Regressão Não Linear**. 2002. 10f. Acta Scientiarum. Maringá, 2002.

MELO, D. C. R.; CASTRO, A. R. **Uma Nova Abordagem para Detecção de Outliers em Séries Temporais: Estudo de Caso em Consumo de Energia na Região Amazônica**. 2013. 4f. Proceeding Series of the Brazilian Society of Applied and Computational Mathematics. 2013.

MÓDOLO, M. **Classificação Automática de Supernovas Usando Redes Neurais Artificiais**. 2016. 233f. Tese de Doutorado – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

OLIVEIRA, H. M. **Análise de Sinais para Engenheiros: Uma Abordagem via Wavelets**. Recife: Brasport. 2007.

PIRES, J. C. L. **Desafios da reestruturação do setor elétrico brasileiro**. [S.l.]: BNDES, Área de Planejamento, Departamento Econômico-DEPEC, 2000. v. 76.

POLIKAR, R. **The wavelet tutorial**. Ames: IOWA State University, 1996.

SEVERO, D. S. **Otimização Global em Redes Neurais Artificiais**. 2010. 63f. Trabalho de Graduação – Universidade Federal de Pernambuco, Recife, 2010.

SPERANDIO, M. **Classificação de conjuntos consumidores de energia elétrica via mapas auto organizáveis e estatística multivariada**. 2004. 105f. Dissertação de Mestrado - Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina. Florianópolis, 2004.

SILVA, A. M. **Utilização de Redes Neurais Artificiais para Classificação de Spam**. 2009. 128f. Dissertação de Mestrado – Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2009.

TIMOSSI, L. S. *et al.* **Análise da qualidade de vida no trabalho de colaboradores com diferentes níveis de instrução através de uma análise de correlações**. 2010. 10f. Ponta Grossa, 2010.

THOMAS, G. **Regressão Não Linear**. 2016. 19f. Universidade de São Paulo. Piracicaba, 2016.

TRONCHONI, A. B. **Identificação de Causas de Desligamentos Não Programados em Redes de Distribuição**. 2008. 131f. Dissertação de Mestrado – Pontifícia Universidade Católica do Rio Grande do Sul - PUCRS, Porto Alegre, 2008.

VIALI, L. **Série Estatística Multivariada**. 22f. Pontifícia Universidade Católica do Rio Grande do Sul - PUCRS. Porto Alegre.
