UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO

JULIANA BARCELLOS MATTOS

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA ESTIMAÇÃO DE INDICADORES DE CONTINUIDADE DO FORNECIMENTO DE ENERGIA ELÉTRICA

VITÓRIA – ES
JANEIRO/2018

JULIANA BARCELLOS MATTOS

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA ESTIMAÇÃO DE INDICADORES DE CONTINUIDADE DO FORNECIMENTO DE ENERGIA ELÉTRICA

Trabalho de Conclusão de Curso da aluna **Juliana Barcellos Mattos**, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica.

Orientador:
Prof. Dr. Oureste Elias Batista

Coorientador:
Eng. Filiphe Oliveira Louback

VITÓRIA – ES
JANEIRO/2018

JULIANA BARCELLOS MATTOS

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA ESTIMAÇÃO DE INDICADORES DE CONTINUIDADE DO FORNECIMENTO DE ENERGIA ELÉTRICA

Parte manuscrita do Projeto de Graduação da aluna **Juliana Barcellos Mattos**, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheira Eletricista.

Aprovado em 5 de janeiro de 2018.

COMISSÃO EXAMINADORA:

_____

Prof. Dr. Oureste Elias Batista
Universidade Federal do Espírito Santo
Orientador

_____

Eng. Filiphe Oliveira Louback
EDP Espírito Santo
Coorientador

_____

Prof. Dr. Patrick Marques Ciarelli
Universidade Federal do Espírito Santo
Examinador

_____

Prof. Dr. Klaus Fabiano Coco
Universidade Federal do Espírito Santo
Examinador

RESUMO

No Brasil, uma das óticas através da qual o desempenho das distribuidoras de energia é avaliado é a Qualidade do Serviço, que regula a continuidade do fornecimento de energia elétrica através dos indicadores de Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e de Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), estando a distribuidora de energia sujeita a penalidades no caso de não cumprimento dos limites regulatórios. A estimação de tais indicadores proporciona, então, um conhecimento do panorama futuro da empresa, oportunizando a identificação prévia de áreas cujos indicadores 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, com o intuito de oferecer um método alternativo aos processos atuais de estimação. O trabalho utiliza dados reais de uma distribuidora de energia da região Sudeste do Brasil e objetiva a estimação dos indicadores DEC e FEC mensais de um conjunto elétrico, para o período de um ano. O resultado obtido para a estimação do DEC apresentou erro quadrático médio significativamente inferior ao erro do método de previsão da distribuidora, sendo viável o modelo proposto. O resultado apresentado pelo modelo de estimação do FEC apresentou erro quadrático médio 20% superior ao apresentado pelo modelo de previsão da empresa, de forma que a rede desenvolvida não se mostrou adequada à aplicação.

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

ABSTRACT

In Brazil, one way of evaluating the performance of energy distributor enterprises is regulating the continuity of energy supplying through two main indicators: the equivalent interruption duration and the equivalent interruption frequency. The enterprises that violate the regulatory limits of those indicators can suffer penalties. In this way, the indicators estimation offers a future perspective of their tendencies, giving the possibility to identify those that have the tendency of getting worse. This project consists of a methodology for continuity indicators estimation based on Artificial Neural Network application, as an alternative method to the current estimation processes. It uses real data from an energy distributor enterprise of Brazilian Southwest region and aims the estimation of continuity monthly indicators of consumer unities group, for one year. The results obtained from the interruptions duration estimation model presented a low mean squares error, significantly lower than the error from the estimation method used by the distributor enterprise, being viable its application. Otherwise, the results obtained by the interruptions' frequency estimation model presented a mean squared error 20% higher than the acquired by the distributor enterprise method for estimation. For that reason, the network is not proper for frequency indicator estimation.

Keywords: Continuity of energy supplying, continuity indicators, Artificial Neural Network applied to continuity indicators estimation.

LISTA DE FIGURAS

Figura 1 – Compensações pagas pelas concessionárias de energia do Brasil 28

Figura 2 - Reajuste Tarifário: parcelas do cálculo 29

Figura 3 - Fator X Reajuste Tarifário: Exemplo gráfico do modelo de cálculo das componentes de Q 31

Figura 4 - Neurônio Artificial 37

Figura 5 - Estrutura de camadas da RNA 38

Figura 6 - Arquitetura *Feedforward* Camada Simples 40

Figura 7 - Arquitetura Feedforward Camadas Múltiplas 40

Figura 8 - Arquitetura Realimentada 40

Figura 9 - Arquitetura em Estrutura Reticulada 40

Figura 10 - Correlação cruzada entre DEC e Quantidade de Interrupções mensais 51

Figura 11 - Correlação das variáveis pré-selecionadas em relação ao DEC 52

Figura 12 - Correlação das variáveis pré-selecionadas em relação ao FEC 52

Figura 13 - Fluxograma do código de treinamento da RNA 56

Figura 14 - Arquitetura da RNA de estimação do DEC 58

Figura 15 - Arquitetura da RNA de estimação do FEC 58

Figura 16 - Resultado da RNA para estimação do DEC 59

Figura 17 – Resultado do método de estimação da Distribuidora para o DEC 59

Figura 18 - Resultado da RNA para estimação do FEC 60

Figura 19 - Resultado do método de estimação da Distribuidora para o FEC 61

LISTA DE TABELAS

Tabela 1- Correlação das variáveis de DEC 53

Tabela 2 - Correlação das variáveis de FEC 53

LISTA DE QUADROS

Quadro 1 - Reajuste Tarifário: Conceito da Tolerância em cada uma das classes do modelo de cálculo das componentes de Q do Fator X 31

Quadro 2 - Fatores Geradores selecionados como variáveis 46

Quadro 3 - Variáveis para análise do DEC 48

Quadro 4 - Variáveis para análise do FEC 49

Quadro 5 - Variáveis para a estimação do DEC 54

Quadro 6 - Variáveis para a estimação do FEC 55

Quadro 7 - Parâmetros das RNA de estimação dos indicadores 57

Quadro 8 - Erros quadráticos médios dos resultados do modelo DEC 58

Quadro 9 - Erros quadráticos médios dos resultados do modelo FEC 60

LISTA DE ABREVIATURAS E SIGLAS

AI	Inteligência Artificial
ANEEL	Agência Nacional de Energia Elétrica
C1_DEC	DEC da causa Papagaio (Pipa)
C1_FEC	DEC da causa Papagaio (Pipa)
C1_QTD	Quantidade de Ordens com Causa Papagaio (Pipa)
C2_DEC	DEC da causa Deterioração de equipamento
C2_FEC	DEC da causa Deterioração de equipamento
C2_QTD	Quantidade de Ordens com Causa Deterioração de equipamento
C3_DEC	DEC da causa Conexão
C3_FEC	DEC da causa Conexão
C3_QTD	Quantidade de Ordens com Causa Conexão
C4_DEC	DEC de causas não determinadas
C4_FEC	DEC da causa Serviço programado com aviso
C4_QTD	Quantidade de Ordens com Causas não determinadas
DEC	Duração Equivalente de Interrupção por Unidade Consumidora
DEC_PROG	DEC programado
DGC	Desempenho Global de Continuidade
DIC	Duração de Interrupção Individual por Unidade Consumidora
DICRI	Duração da Interrupção Individual Ocorrida em Dia Crítico por Unidade Consumidora
DMIC	Duração Máxima de Interrupção Contínua por Unidade Consumidora
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora
FEC_PROG	FEC programado
FER	Frequência Equivalente de Reclamação
FIC	Frequência de Interrupção Individual por Unidade Consumidora
IAb	Índice de Abandono
IASC	Índice ANEEL de Satisfação do Consumidor
ICO	Índice de Chamadas Ocupadas
IGP-M	Índice Geral de Preços de Mercado
INS	Índice de Nível de Serviço
IoT	Internet das Coisas

IPCA	Índice Nacional de Preços ao Consumidor
PRODIST	Procedimentos de Distribuição
QEE	Qualidade da Energia Elétrica
QTD	Quantidade de interrupções de energia
QTD_PROG	Quantidade de interrupções de energia programadas
QTD_SEMINT	Quantidade de ordens de atendimento sem interrupção de energia
RNA	Redes Neurais Artificiais
TMA	Tempo médio de atendimento
TMD	Tempo médio de deslocamento
TMP	Tempo médio de preparo
TMR	Tempo médio de reparo

SUMÁRIO

1 INTRODUÇÃO AO PROJETO DE GRADUAÇÃO 19
1.1 APRESENTAÇÃO 19
1.2 JUSTIFICATIVA E MOTIVAÇÃO DO PROJETO 21
1.3 OBJETIVOS DO PROJETO 22
1.4 ORGANIZAÇÃO DO PROJETO 22
2 INDICADORES DE CONTINUIDADE DO FORNECIMENTO DE ENERGIA ELÉTRICA 25
2.1 INTRODUÇÃO: A QUALIDADE DO SERVIÇO E OS INDICADORES DE CONTINUIDADE 25
2.1.1 INDICADORES INDIVIDUAIS DE CONTINUIDADE 25
2.1.2 INDICADORES COLETIVOS DE CONTINUIDADE 26
2.1.3 COMPENSAÇÕES PELA TRANSGRESSÃO DOS LIMITES DE CONTINUIDADE 27
2.2 REGULAÇÃO DOS SERVIÇOS DE DISTRIBUIÇÃO 27
2.3 O DESEMPENHO DA CONTINUIDADE 28
2.4 A ESTIMAÇÃO DE INDICADORES 32
3 APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS 34
3.1 INTRODUÇÃO: INTELIGÊNCIA ARTIFICIAL 34
3.2 REDES NEURAIS ARTIFICIAIS 36
3.2.1 CONCEITO 36
3.2.2 FUNCIONAMENTO: NEURÔNIOS ARTIFICIAIS 36
3.2.3 CAMADAS E ARQUITETURAS DA REDE 38
3.2.3.1 Arquitetura *Feedforward* de Camada Simples 39
3.2.3.2 Arquitetura *Feedforward* de Camadas Múltiplas 39
3.2.3.3 Arquitetura Recorrente ou Realimentada 39
3.2.3.4 Arquitetura em Estrutura Reticulada 39
3.2.4 BENEFÍCIOS DA APLICAÇÃO DE RNA 40
3.3 ESTIMADOR NEURAL 41
4 METODOLOGIA PARA ESTIMAÇÃO DOS INDICADORES 42
4.1 INTRODUÇÃO 42
4.2 DEFINIÇÃO DE ESCOPO 43
4.2.1 PREMISSAS DO PROJETO 43

4.2.2 DESCRIÇÃO DOS DADOS 43
4.2.3 IDENTIFICAÇÃO DAS VARIÁVEIS INICIAIS DO SISTEMA 45
4.2.3.1 Seleção das variáveis de Causa de interrupção 45
4.2.3.2 Variáveis para análise do DEC 48
4.2.3.3 Variáveis para análise do FEC 48
4.3 ANÁLISE E PRÉ-PROCESSAMENTO DOS DADOS 49
4.3.1 ANÁLISE DE CORRELAÇÕES DOS DADOS 50
4.3.1.1 Análise do padrão de correlação entre amostras e atrasos 50
4.3.1.2 Análise de variáveis através de Intervalo de Confiança e Correlação. 51
4.3.2 IDENTIFICAÇÃO DAS VARIÁVEIS DE ENTRADA DO SISTEMA 53
4.4 CONSTRUÇÃO DA REDE NEURAL ARTIFICIAL 55
5 RESULTADOS 57
5.1 INTRODUÇÃO 57
5.2 ESTIMAÇÃO DOS INDICADORES 58
5.2.1 RNA DE ESTIMAÇÃO DO DEC 58
5.2.2 RNA DE ESTIMAÇÃO DO FE 59
5.3 CONSIDERAÇÕES FINAIS 61
6 CONCLUSÕES E TRABALHOS FUTUROS 62
6.1 CONCLUSÕES 62
6.2 TRABALHOS FUTUROS 63
REFERÊNCIAS BIBLIOGRÁFICAS 64

1 INTRODUÇÃO AO PROJETO DE GRADUAÇÃO

1.1 APRESENTAÇÃO

Com a expansão tecnológica na qual as sociedades fundamentam-se nos dias atuais, a disponibilidade de acesso à energia elétrica tornou-se uma questão crucial no modo de vida das pessoas. Seja para desenvolvimento de bens de consumo, atividades empresariais, atividades comerciais ou apenas atividades de lazer, a energia elétrica faz-se presente em cada um dos aspectos da vida cotidiana, interferindo todas as relações sociais. A energia elétrica deixou de ser um privilégio e tornou-se necessária para o funcionamento da vida social. Nesse contexto, problemas como falta de energia e alterações na tensão fornecida caracterizam empecilhos às atividades do dia-a-dia. Surge a necessidade da garantia de um fornecimento de energia elétrica de qualidade.

Para garantir a qualidade do fornecimento de energia, cada país possui seu conjunto de regras regulatórias e métodos de fiscalização. No Brasil, Agência Nacional de Energia Elétrica – ANEEL – responsável pela regulação e fiscalização do setor elétrico brasileiro, regulamenta a qualidade do sistema de distribuição de energia elétrica percebida pelo consumidor sob a ótica de três aspectos distintos:

- A Qualidade do Produto: relacionada à conformidade da tensão em regime permanente e à ausência de perturbações na prestação de serviço;
- A Qualidade do Serviço: relacionada à continuidade na prestação de serviço;
- A Qualidade do Atendimento ao Consumidor: referente à qualidade do atendimento comercial, à qualidade do atendimento telefônico e ao tratamento das informações.

A regulação da qualidade do sistema de distribuição é fundamentada na existência de indicadores da qualidade que são fiscalizados por meio de limites, individuais e coletivos, estipulados segundo os procedimentos referentes à Qualidade da Energia Elétrica (QEE) estabelecidos no Módulo 8 dos Procedimentos de Distribuição – PRODIST (ANEEL, 2017). Os indicadores de continuidade do fornecimento de energia, escopo da Qualidade do Serviço, objeto deste projeto, monitoram, em termos gerais, a frequência e a duração das interrupções do fornecimento, e serão abordados mais especificamente no próximo capítulo deste documento.

A ocorrência de interrupções do fornecimento de energia elétrica está intimamente relacionada a fatores externos que agem sobre as redes de distribuição. No Brasil existem quatro tipos de redes de distribuição de energia elétrica: aéreas convencionais, aéreas compactas, aéreas isoladas e subterrâneas, sendo a primeira destas a mais encontrada, caracterizada por condutores nus (sem isolamento) e, portanto, mais suscetíveis a ações externas. Nesse contexto, interrupções no fornecimento de energia elétrica são comumente ocasionadas por causas como deterioração de equipamentos, galhos de árvore tocando a rede, animais acarretando curtos circuitos, descargas atmosféricas, dentre outros. Dessa forma, o controle sobre frequência e duração de interrupções no fornecimento de energia torna-se um desafio às concessionárias, que precisam agir corretivamente em resposta a essas influências externas e identificar formas para mitigar seus impactos nos indicadores da empresa.

No entanto, se por um lado há o aspecto regulamentar dos indicadores de continuidade do fornecimento, cuja não adequação aos limites regulatórios acarreta pagamentos de compensações aos clientes e é passível de multa, por outro, o bom desempenho em tais indicadores é recompensado pela ANEEL através de ajuste tarifário anual como incentivo à busca pela melhoria contínua da qualidade do serviço. Dessa forma, a manutenção desses indicadores dentro dos limites regulados é essencial para o cumprimento da regulação, e medidas de otimização do desempenho destes indicadores pode levar a ganhos financeiros por parte da empresa.

Neste sentido, o presente trabalho objetiva a elaboração de uma metodologia para estimar os indicadores de continuidade do fornecimento para que seja possível a identificação de regiões que possuem tendência de piora dos mesmos e de possíveis causas que ocasionem tal tendência, oportunizando ações preventivas com o intuito de mitigar os impactos dessas áreas no resultado futuro dos indicadores, prevenindo a violação dos limites regulamentares. Por outro lado, também é possível identificar oportunidades de ações que contribuam para a melhoria dos resultados destes indicadores, colaborando para a melhoria da qualidade percebida pelo cliente e, consequentemente, visando os incentivos de não redução tarifária.

1.2 JUSTIFICATIVA E MOTIVAÇÃO DO PROJETO

A estimação de indicadores de continuidade do fornecimento de energia proporciona um conhecimento do panorama futuro da empresa, oportunizando a identificação prévia de áreas cujos indicadores possuem tendência de piora no tempo. Tal identificação oferece à empresa distribuidora a possibilidade da realização de estudos específicos direcionados às regiões apontadas, no sentido de identificar causas recorrentes de interrupções e oportunidades de realização de ações preventivas, sejam ações operacionais ou de investimento de capital, a fim de melhorar a qualidade do fornecimento de energia nessas áreas e mitigar o impacto das mesmas sobre os indicadores da empresa, resultando em melhor adequação às normas regulamentares, melhores resultados em *ranking* de indicadores e menores gastos com compensações por violação de indicadores individuais de continuidade.

No entanto, não existe um método específico para estimar os indicadores. Cada empresa, em geral, desenvolve um método próprio para estimação, normalmente baseados em métodos estatísticos, análises de dados da operação e manutenção, metodologia específica, e orientando-se pela experiência adquirida com os anos de trabalho na análise dos dados em específico. Tais métodos costumam ser de complexa compreensão, difícil aplicação e exigem de quem os utiliza um domínio e conhecimento muito grandes dos dados envolvidos. Existem, entretanto, novos conceitos de análise de dados, surgidos a partir de sistemas inteligentes, que consistem em ferramentas de engenharia aplicada, e que permitem o desenvolvimento de metodologias que utilizem ferramentas de fácil aplicação e possuam resultados confiáveis.

Nesse contexto, com a motivação de prover solução alternativa para a estimação dos indicadores de qualidade do fornecimento das concessionárias de energia, visando a melhoria da qualidade do serviço prestado pelas empresas distribuidoras, e objetivando a otimização dos processos de estimação de indicadores, o presente trabalho consiste no desenvolvimento de uma metodologia de estimação de indicadores de continuidade do fornecimento utilizando a aplicação de Redes Neurais Artificiais, com o intuito de oferecer um método alternativo aos processos atuais de estimação que seja eficiente, baseado em ferramentas de engenharia de análise de dados e que apresente resultados confiáveis.

1.3 OBJETIVOS DO PROJETO

O presente projeto objetiva o estudo de uma metodologia de Rede Neural Artificial para estimar indicadores de continuidade do fornecimento de distribuidoras de energia elétrica, tendo como base o histórico de indicadores apurados e o histórico de ordens de atendimento.

1.4 ORGANIZAÇÃO DO PROJETO

Este documento encontra-se dividido em capítulos organizados de tal forma que os assuntos são apresentados com evolução gradativa, de forma que, para compreensão do trabalho como um todo, é imprescindível a leitura sequencial de todo o documento. Entretanto, cada capítulo é consistente no escopo que propõe, de forma a proporcionar compreensão do assunto abordado independente da leitura completa do trabalho.

O Capítulo 1 apresenta o contexto da proposta deste trabalho, abordando as justificativas e motivações do desenvolvimento deste projeto assim como seus objetivos.

O Capítulo 2 aborda o contexto da Qualidade da Distribuição de energia elétrica no Brasil, apresentando os indicadores de continuidade do fornecimento, individuais e coletivos, e o contexto regulatório no qual estão inseridos. O capítulo é finalizado com a apresentação das abordagens metodológicas de trabalhos desenvolvidos ao longo dos anos com o objetivo de estimar os indicadores de continuidade.

O Capítulo 3 consiste em uma revisão bibliográfica sobre o uso de redes neurais artificiais (RNA), apresentando brevemente o contexto de desenvolvimento de sistemas inteligentes e suas aplicações, e então fazendo uma revisão breve sobre o conceito de RNA, seu funcionamento e características e as principais vantagens de sua aplicação.

O Capítulo 4 apresenta a metodologia utilizada para a construção do sistema de estimação de cada indicador. São apresentadas as premissas do projeto e é feita a descrição detalhada dos dados. É descrita toda a metodologia de seleção das variáveis de entrada da RNA, apresentando as variáveis selecionadas, e é apresentada a metodologia de treinamento da rede.

O Capítulo 5 apresenta a análise dos resultados obtidos com as redes de estimação dos indicadores através da validação do modelo proposto de rede e a comparação dos valores de

erro obtidos com o modelo empresarial de estimação. O Capítulo 6, por fim, traz as conclusões sobre a metodologia desenvolvida, apontando as possibilidades de aprimoramentos e perspectivas para trabalhos futuros.

2 INDICADORES DE CONTINUIDADE DO FORNECIMENTO DE ENERGIA ELÉTRICA

2.1 INTRODUÇÃO: A QUALIDADE DO SERVIÇO E OS INDICADORES DE CONTINUIDADE

A qualidade do serviço, um dos aspectos que compõe a qualidade da distribuição de energia elétrica, compreende a avaliação das interrupções no fornecimento de energia. Para tal finalidade, são utilizados indicadores de continuidade que, em termos gerais, monitoram a duração e a frequência das interrupções, destacando-se os indicadores de continuidade coletivos (DEC e FEC) e os indicadores de continuidade individuais (DIC, FIC, DMIC e DICRI), todos definidos no Módulo 8 do PRODIST (ANEEL, 2017). De forma similar a outros países, tais indicadores são apurados para interrupções sustentadas, ou seja, interrupções no fornecimento maiores que 3 minutos, e sendo admitidos expurgos na apuração. Objetivando a manutenção da qualidade na prestação do serviço público de distribuição de energia, a ANEEL estabelece metas para os indicadores de continuidade coletivos e limites para os indicadores de continuidade individuais.

2.1.1 INDICADORES INDIVIDUAIS DE CONTINUIDADE

Os indicadores individuais de continuidade são associados a cada unidade consumidora e monitoram a qualidade do fornecimento de energia percebida pelo cliente, em termos de duração e frequência de interrupções. São estes os indicadores individuais definidos em (ANEEL, 2017):

- Duração de interrupção individual por unidade consumidora (DIC): Intervalo de tempo que, no período de apuração, em cada unidade consumidora ou ponto de conexão, ocorreu descontinuidade da distribuição de energia elétrica;
- Frequência de interrupção individual por unidade consumidora (FIC): Número de interrupções ocorridas, no período de apuração, em cada unidade consumidora ou ponto de conexão;

- Duração máxima de interrupção contínua por unidade consumidora ou ponto de conexão (DMIC): Tempo máximo de interrupção contínua de energia elétrica, em uma unidade consumidora ou ponto de conexão; e
- Duração da interrupção individual ocorrida em dia crítico por unidade consumidora ou ponto de conexão (DICRI): Corresponde à duração de cada interrupção ocorrida em dia crítico[1], para cada unidade consumidora ou ponto de conexão.

No que diz respeito aos limites estipulados pela ANEEL: os limites de DIC e FIC são definidos para períodos mensais, trimestrais e anuais; o limite do indicador DMIC é definido apenas para períodos mensais; e o limite de DICRI é definido para cada interrupção em dia crítico. Tais limites variam de acordo com a faixa de tensão contratada pelo cliente e a área geográfica do mesmo (área urbana ou rural). O Módulo 8 do PRODIST (ANEEL, 2017) abrange toda a normativa referente aos indicadores de continuidade e seus limites.

2.1.2 INDICADORES COLETIVOS DE CONTINUIDADE

Entendem-se por indicadores coletivos de continuidade o DEC (Duração Equivalente de Interrupção por Unidade Consumidora) e o FEC (Frequência Equivalente de Interrupção por Unidade Consumidora). Tais indicadores objetivam a avaliação da continuidade do fornecimento através de subdivisões das distribuidoras, denominadas Conjuntos Elétricos, compostos por uma ou mais Subestação de Distribuição, conforme definido na Seção 8.2 do Módulo 8 do PRODIST (ANEEL, 2017).

Para cada Conjunto Elétrico de unidades consumidoras, a ANEEL avalia o desempenho estipulando limites para os indicadores coletivos de continuidade e as distribuidoras de energia são responsáveis pela apuração e envio periódicos dos mesmos à ANEEL, segundo regras específicas determinadas no Módulo 8 do PRODIST (ANEEL, 2017).

---

[1] Dia em que a quantidade de ocorrências emergenciais, em um determinado conjunto de unidades consumidoras, superar a média acrescida de três desvios padrões dos valores diários. (ANEEL, 2018)

2.1.3 COMPENSAÇÕES PELA TRANSGRESSÃO DOS LIMITES DE CONTINUIDADE

Em caso de violação dos limites dos indicadores individuais de continuidade, a concessionária está obrigada a realizar compensações pela transgressão ocorrida, que é feita automaticamente em forma de crédito na fatura, em até dois meses após o período de apuração dos indicadores. As normas regulamentares para o cálculo de pagamento das compensações são definidas no Módulo 8 do PRODIST (ANEEL, 2017).

Quando analisados a nível de compensações individuais, os valores para unidades consumidoras residenciais, principalmente de áreas não-urbanas, são irrisórios, e, muitas vezes, não há conformidade entre os valores pagos pelo serviço de energia e os valores de compensações pelo não fornecimento da mesma. Por outro lado, quando somados todos esses valores irrisórios de compensações individuais, a quantia gasta por distribuidoras de energia para pagamento de compensações atinge a casa dos milhões anuais. A Figura 1 apresenta os gráficos da quantidade de compensações pagas pelas concessionárias de energia do Brasil nos anos de 2010 a 2017 e o montante pago nesse período de tempo. Para o ano de 2017, foram pagos R$ 313.990.353,06 por um total de 68.510.543 compensações, o que equivale a um valor médio de aproximadamente R$ 4,58 por compensação.

2.2 REGULAÇÃO DOS SERVIÇOS DE DISTRIBUIÇÃO

A ANEEL é uma autarquia vinculada ao Ministério de Minas e Energia, cuja função é regular e fiscalizar a produção, transmissão, distribuição e comercialização de energia elétrica no Brasil. Compete à mesma regulamentar as políticas e diretrizes do Governo para a utilização e exploração dos serviços de energia elétrica e definir padrões de qualidade do atendimento e de segurança, promovendo o uso eficaz de energia elétrica e proporcionando condições para a livre competição no mercado de energia. A ANEEL, portanto, pratica três modalidades de regulação:

- Regulação técnica de padrões de serviço (geração, transmissão, distribuição e comercialização);
- Regulação econômica (tarifas e mercado); e
- Regulação de projetos de pesquisa e desenvolvimento (P&D) e eficiência energética.

Figura 1 – Compensações pagas pelas concessionárias de energia do Brasil

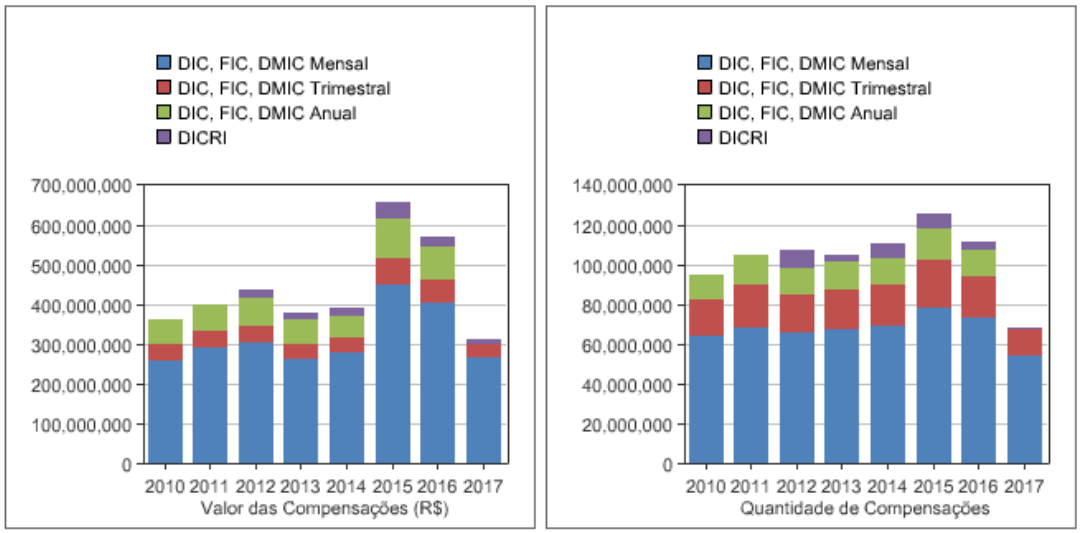

Fonte: ANEEL (2018)

Segundo o regimento interno da ANEEL, a regulação técnica dos serviços de distribuição de energia é de responsabilidade da Superintendência de Regulação dos Serviços de Distribuição (SRD), a quem compete, dentre outras funções, o estabelecimento de regras e de procedimentos referentes à definição e acompanhamento de indicadores de qualidade do serviço e do produto energia elétrica.

Para assegurar que toda e qualquer alteração regulatória prime pelo benefício social, a ANEEL estipulou, em resolução normativa, a obrigatoriedade da realização de Análise de Impacto Regulatório (AIR) antes da expedição de qualquer ato normativo. A AIR tem o objetivo de prover informações sobre a necessidade e as consequências da regulação que está sendo proposta, verificando se os benefícios potenciais da medida excedem os custos estimados, e se, dentre todas as alternativas avaliadas, a ação é a mais benéfica para a sociedade.

2.3 O DESEMPENHO DA CONTINUIDADE

Como forma de incentivar as distribuidoras a investir na melhoria da qualidade do serviço prestado, a ANEEL incluiu no cálculo de reajuste da tarifa de energia uma componente que avalia a qualidade dos serviços técnicos e comerciais prestados por cada distribuidora aos seus consumidores, como sendo componente integrante do Fator X. Tal fator consiste em um índice fixado pela ANEEL, para a revisão tarifária, cuja função é repassar ao consumidor os ganhos

de produtividade estimados da concessionária, compreendendo benefícios financeiros para, tanto consumidores, quanto empresas.

Para o cálculo do reajuste tarifário são levadas em considerações as variações dos custos referentes a duas parcelas distintas (conforme ilustrado na Figura 2):

- Parcela A: que são custos sob os quais a distribuidora tem pouca ou nenhuma gestão, que se referem à compra de energia elétrica para atendimento do mercado, transmissão dessa energia até a área da distribuidora e os encargos setoriais.
- Parcela B: que é de completa gestão da distribuidora e refere-se aos custos com a atividade de distribuição, ou seja, custos operacionais, custos relacionados a investimentos realizados pela distribuidora, quota de depreciação dos ativos e remuneração regulatória, corrigidos pelo índice de inflação constante no contrato de concessão – IPCA (Índice Nacional de Preços ao Consumidor)[2] ou IGP-M (Índice Geral de Preços de Mercado)[3] – deduzido o Fator X.

Figura 2 - Reajuste Tarifário: parcelas do cálculo

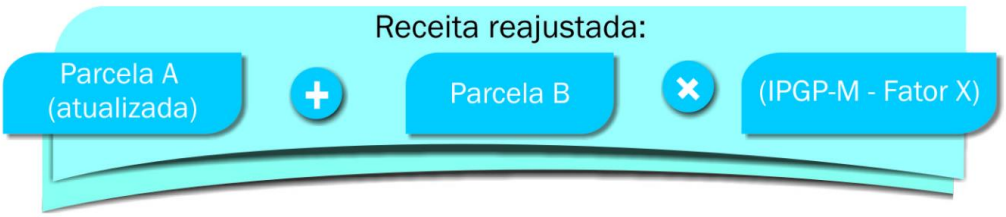

FONTE: ANEEL (2017)

---

[2] Índice criado para medir a variação de preços do mercado para o consumidor final. A partir de novembro de 1985, de acordo com o Decreto n. 91.990, o IPCA passou a ser utilizado como indexador oficial do País, corrigindo salários, aluguéis, taxa de câmbio, poupança, além dos demais ativos monetários. (IBGE, 2018)

[3] Índice utilizado para a correção de contratos de aluguel e como indexador de algumas tarifas como energia elétrica. (FGV, 2018)

O objetivo do Fator X é estimar ganhos de produtividade da atividade de distribuição, utilizando-os em favor da modicidade tarifária em cada reajuste, funcionando, na maioria das vezes, como um redutor dos índices de reajuste das tarifas cobradas aos consumidores. É composto por três componentes: o componente Pd, que mensura os ganhos de produtividade das distribuidoras de energia elétrica; o componente Q, que avalia a qualidade dos serviços técnicos e comerciais prestados por cada distribuidora aos seus consumidores; e o componente T, que ajusta, ao longo de um período definido, os custos operacionais observados de cada concessionária ao custo operacional eficiente.

O componente de qualidade (Q) do Fator X é composto por duas parcelas: a parcela de qualidade comercial ($Q_{Comercial}$), que leva em consideração os indicadores de qualidade comercial INS, ICO, IAb, FER e IASC (não abordados no presente trabalho); e a parcela de qualidade técnica ($Q_{Técnico}$) que leva em consideração os indicadores de continuidade DEC e FEC, e corresponde a setenta por cento (70%) da componente Q. Cada parcela é função da variação de seus indicadores de qualidade e, em última instância, acarretam aumento ou redução da tarifa de energia e indicam melhora/piora da qualidade.

O Módulo 8 do PRODIST prevê, então, o Indicador de Desempenho Global de Continuidade (DGC), também conhecido como "*Ranking* da Continuidade". Tal indicador tem como finalidade avaliar o nível de continuidade das distribuidoras em relação aos limites estabelecidos para sua área de concessão, comparando o desempenho de uma distribuidora em relação às demais do Brasil.

As concessionárias de energia são divididas, segundo a avaliação anual do *ranking* de continuidade dos serviços (incorporando também os indicadores comerciais), em dois grupos: as que atendem ao padrão e as que não atendem ao padrão estabelecido. E esses dois grupos são subdivididos em duas classes, uma composta por 25% das melhores (ou piores) concessionárias e, a outra classe, composta pelas demais 75%, conforme Figura 3.

Figura 3 - Fator X Reajuste Tarifário: Exemplo gráfico do modelo de cálculo das componentes de Q

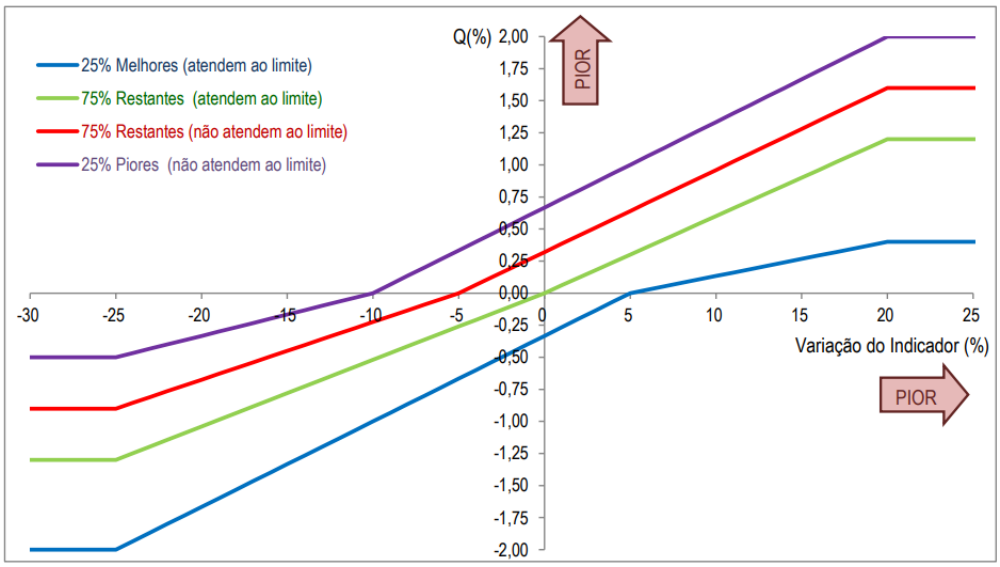

FONTE: ANEEL (2017)

Dessa forma, a ANEEL estipula margens de tolerância a variações na qualidade, e incentivos à melhoria constante da mesma, através do reajuste tarifário seguindo as regras conforme apresentado no Quadro 1.

Quadro 1 - Reajuste Tarifário: Conceito da Tolerância em cada uma das classes do modelo de cálculo das componentes de Q do Fator X

Condição	Classe	Regra geral para a tolerância
Atende ao padrão	25% melhores	Essa classe, em geral, possui tolerância para que o indicador de qualidade piore sem que, com isso, sofra efeito de redução de tarifa. No exemplo da Figura 3, essa tolerância é de 5%, ou seja, mesmo que o indicador de qualidade piore em até 5% em relação ao ano anterior, a distribuidora ainda não tem efeito redutor na tarifa.
	75% restantes	Essa classe possui tolerância zero e, assim, qualquer piora no seu indicador leva a efeito redutor da tarifa.
Não atende ao padrão	75% restantes	Essa classe necessita melhorar seu indicador a partir de certo nível para obter Qi negativo. No exemplo da Figura 3, essa tolerância é de -5%, ou seja, o indicador de qualidade deve melhorar mais que 5% para ter efeito de elevação da tarifa.
	25% piores	Essa classe possui tolerância menor que a anterior. No exemplo da Figura 3**Erro! Fonte de referência não encontrada.**, essa tolerância é de -10%, ou seja, o indicador de qualidade tem de melhorar mais que 10% para surtir efeito de elevação da tarifa.

FONTE: ANEEL (2017)

Portanto, se as exigências regulatórias oferecem uma margem de conforto às concessionárias através do atendimento aos limites exigidos, a ANEEL oferece incentivos em reajustes tarifários para os melhores desempenhos de continuidade e utiliza-se do *benchmarking* para fomentar a busca pela melhoria contínua da qualidade do serviço prestado pelas distribuidoras, uma vez que o resultado do desempenho de cada distribuidora é avaliado em relação ao desempenho das demais. Por conseguinte, uma vez que o desempenho de cada empresa é pautado nos resultados de seus indicadores de continuidade, a otimização de tais resultados torna-se crucial na avaliação de cada distribuidora.

2.4 A ESTIMAÇÃO DE INDICADORES

Devido à sua relevância nas atuais discussões envolvendo distribuição de energia, a Qualidade da Energia Elétrica (QEE) tem sido assunto amplamente discutido em simpósios e congressos da área, como o Seminário Nacional de Distribuição de Energia Elétrica (SENDI) e a Conferência Brasileira sobre Qualidade da Energia Elétrica (CBQEE). Dentre as diversas temáticas que compõem a QEE, há estudos e artigos publicados nesses eventos, tal como dissertações de mestrado, que fazem abordagens diferenciadas objetivando a estimação dos indicadores de continuidade.

Ewald (2006) apresenta um método de acompanhamento diário da evolução dos indicadores através do desdobramento das metas anuais em metas mensais e diárias. A previsão é feita baseada em séries históricas dos indicadores, através de Curvas Guias que representam a tendência do comportamento dos indicadores, calculadas utilizando-se média ponderada dos indicadores históricos de determinado período e aplicando-se linha de tendência utilizando-se equação polinomial.

Gontijo (2007) faz a estimação de indicadores de continuidade através da modelagem equacional dos mesmos utilizando a taxa de falha e do tempo médio de reestabelecimento, ambos estimados com base na utilização de regressões lineares e elementos da teoria da decisão estatística.

Araújo Jr. (2016) propõe o desenvolvimento de um modelo de estimação dos indicadores de continuidade baseado na Análise de Regressão Linear Múltipla, utilizando histórico de ocorrência de falhas, ou seja, interrupções no fornecimento de energia. Magalhães (2017) utiliza

como entradas as quantidades de horas de interrupção de fornecimento de energia e as quantidades de interrupções de energia, ambas em função de cada tipo de modo de falha, para o desenvolvimento de modelos utilizando técnicas de Regressão Linear Múltipla e de Redes Neurais Artificiais.

No contexto da fiscalização da distribuição, é possível concluir que técnicas de manutenção preventiva são cada vez mais relevantes para obtenção de melhores resultados no que diz respeito à Qualidade da Energia Elétrica. Nesse sentido, as diversas abordagens de trabalhos distintos evidenciam a aplicabilidade da estimação dos indicadores de continuidade como contribuição relevante na busca pela melhoria da QEE.

O presente trabalho baseia-se em modelo de Redes Neurais Artificiais para estimação dos indicadores DEC e FEC, conforme definidos na Seção 2.1.2.

3 APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS

3.1 INTRODUÇÃO: INTELIGÊNCIA ARTIFICIAL

Ao longo dos séculos, a capacidade de compreensão do meio, de raciocínio e de análise crítica permitiram aos seres humanos desenvolverem-se como sociedade, criando e evoluindo seus meios de interação. A história da humanidade passou por alguns marcos de profundas transformações em sua forma de trabalho, transformando a configuração econômica e sociocultural dos países. A Primeira Revolução Industrial, ocorrida entre meados dos séculos XVIII e XIX, caracterizou-se pelo uso de tecnologias mecânicas, movidas principalmente a vapor, na substituição de processos manuais e força animal, promovendo a mecanização da produção. A Segunda Revolução, ocorrida ao final do século XIX e início do século XX, introduziu o uso de energia elétrica para produção em larga escala. A Terceira Revolução Industrial, datada já da segunda metade do século XX, é o advento da informática, da eletrônica, das tecnologias de informação e das telecomunicações, possibilitando o mundo interconectado com é atualmente. Schwab (2015) define a Quarta Revolução Industrial uma revolução digital, caracterizada pela fusão de tecnologias ocasionando a interação dos universos físico, digital e biológico, cuja amplitude e velocidade de mudança anunciam a transformação de sistemas inteiros de produção, gerenciamento e governança. Nesse contexto, destacam-se tecnologias disruptivas como Inteligência Artificial (AI), Robótica, Internet das Coisas (IoT), Nanotecnologia, Biotecnologia, Computação Quântica, dentre outras várias tecnologias já existentes e em desenvolvimento atualmente.

Nessa seção será realizada uma breve abordagem sobre Inteligência Artificial e suas vertentes de estudo e aplicação como embasamento de posterioras abordagens sobre Redes Neurais Artificiais, objeto de estudo do presente trabalho.

Conhecido como o pai da Inteligência Artificial, John McCarthy definiu Inteligência Artificial como a ciência e engenharia de fazer máquinas inteligentes. Definições mais modernas afirmam que Inteligência Artificial é o estudo e projeto de agentes inteligentes, sendo agentes inteligentes um sistema capaz de perceber seu ambiente e decidir ações que maximizem suas chances de sucesso.

Baseada em disciplinas como Ciências da Computação, Psicologia, Biologia, Matemática, Engenharias, Neurociência e Linguística, o campo da Inteligência Artificial busca desenvolver funções computacionais com habilidades da inteligência humana, tais como raciocínio, aprendizado e solução de problemas, tendo como objetivos: 1) criar sistemas que apresentam comportamento inteligente, ou seja, aprendem, demonstram, explicam e orientam os usuários; e 2) criar sistemas que entendem, pensam, aprendem e comportam-se como seres humanos.

Embora o campo de estudo da Inteligência Artificial seja vasto, segundo *Artificial Intelligence* (2017), destacam-se cinco áreas de pesquisa:

1. Sistemas Especialistas: sistemas desenvolvidos para resolver problemas complexos em um determinado domínio com a inteligência e perícia de um especialista humano.
2. Redes Neurais Artificiais: técnica computacional que consiste em um modelo matemático baseado na estrutura neural do cérebro humano capaz de aprendizado através de treinamento e experiência.
3. Robótica: área da AI que estuda a criação de robôs inteligentes e eficientes, sendo robôs agentes artificiais que agem em ambientes do mundo real.
4. Lógica Fuzzy: sistema que se assemelha ao raciocínio humano, buscando imitar tomadas de decisão humana que envolvem possibilidades intermediárias a respostas de SIM e NÃO. Os sistemas de lógica Fuzzy produzem saídas definitivas e aceitáveis a partir de entradas incompletas, ambíguas, distorcidas e imprecisas.
5. Processamento de Linguagem Natural: método que busca a comunicação com um sistema inteligente através do uso de uma linguagem natural, como o Português, por exemplo. A máquina é, portanto, dotada da capacidade de compreensão da língua e de produção de frases significativas na linguagem natural, seja em linguagem falada ou escrita.

O presente trabalho consiste em uma aplicação de Redes Neurais Artificiais devido à aplicabilidade oferecida por sua capacidade de aprendizado através de treinamentos com dados.

3.2 REDES NEURAIS ARTIFICIAIS

3.2.1 CONCEITO

Entende-se Redes Neurais Artificiais como modelos computacionais inspirados na estrutura neural de aprendizado do cérebro humano que buscam imitar sua forma de resolver problemas. Haykin (2001) afirma que, em termos gerais, as redes neurais artificiais são máquinas que modelam a maneira do cérebro humano de realizar tarefas ou funções específicas. Entendida como uma máquina adaptativa, o autor define uma RNA como sendo:

> [...] um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos:
>
> 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
> 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido. (p. 28)

As RNA consistem, então, em unidades de processamento compostas por múltiplos nós, que imitam os neurônios do cérebro humano. Tais nós são também chamados neurônios da RNA. Eles são conectados por *links* – chamados interconexões ou sinapses artificiais – e interagem entre si. Funcionam recebendo informações de entrada e realizando operações simples com os dados recebidos e o resultado dessas operações é passada para outros neurônios. Cada *link* de conexão é associado a um peso, cujos valores influenciam na capacidade de aprendizado da rede. (Artificial Intelligence, 2017)

3.2.2 FUNCIONAMENTO: NEURÔNIOS ARTIFICIAIS

Silva, Spatti e Flauzino (2010) apresentam uma representação de cada neurônio artificial da rede conforme a Figura 4, afirmando sua constituição através de sete elementos básicos. Sejam os elementos básicos que constituem cada neurônio artificial:

1. <u>Sinais de entrada</u> $\{X_1, X_2, \dots, X_n\}$: dados de entrada que representam os valores das variáveis do problema. São geralmente normalizados a fim de aumentar a eficiência computacional dos algoritmos de aprendizagem.

2. Pesos sinápticos $\{W_1, W_2, \dots, W_n\}$: valores usados para ponderar cada uma das variáveis de entrada da RNA, sendo uma quantificação da relevância de cada variável.
3. Combinador Linear {S}: agrega todos os sinais de entrada já ponderados pelos pesos sinápticos produzindo um valor de potencial de ativação.
4. Limiar de ativação $\{\Theta\}$: variável que determina o valor mínimo do resultado gerado pelo combinador linear para que seja gerado um disparo em direção à saída do neurônio.
5. Potencial de ativação $\{u\}$: diferença entre o valor produzido no combinador linear e o valor do limiar de ativação.
6. Função de ativação $\{g\}$: limita a saída do neurônio a um intervalo de valores.
7. Sinal de saída $\{y\}$: valor final produzido pelo neurônio em relação a um conjunto de entradas, e pode ser utilizado por outros neurônios, se sequencialmente interconectados.

Figura 4 - Neurônio Artificial

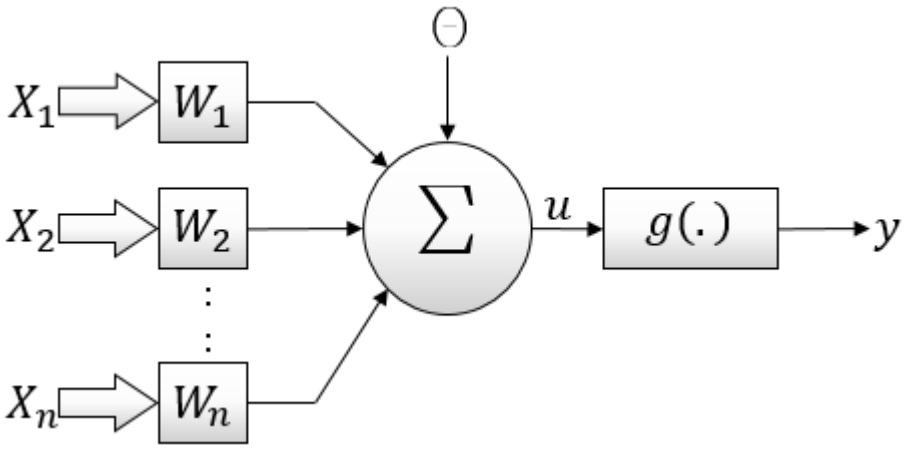

FONTE: Adaptado de Silva, Spatti e Flauzino (2010, p. 34)

Dessa forma, resume-se o funcionamento de um neurônio artificial da seguinte forma:

> 1) Apresentação de um conjunto de valores que representam as variáveis de entrada do neurônio;
> 2) Multiplicação de cada entrada do neurônio pelo seu respectivo peso sináptico;
> 3) Obtenção do potencial de ativação produzido pela soma ponderada dos sinais de entrada, subtraindo-se o limiar de ativação;
> 4) Aplicação de uma função de ativação apropriada, tendo-se como objetivo limitar a saída do neurônio;
> 5) Compilação da saída a partir da aplicação da função de ativação neural em relação ao seu potencial de ativação.
> (SILVA, SPATTI e FLAUZINO, 2010, p. 35)

3.2.3 CAMADAS E ARQUITETURAS DA REDE

Na seção anterior foi descrita a estrutura de um neurônio artificial. No entanto, as RNA são compostas por vários neurônios, dispostos em camadas, que podem ser classificadas em três tipos, conforme descrito abaixo e mostrado na Figura 5:

- Camada de entrada: é a camada que recebe as informações/dados provenientes do meio externo. Haykin (2001) se refere a essa camada como "nós de fonte", pois neles não é realizado nenhuma computação. Nessa camada, em geral, os dados de entrada são normalizados segundo suas funções de ativação para otimizar o desempenho das operações matemáticas ao longo da rede.
- Camadas ocultas: também chamadas de camadas escondidas, intermediárias ou invisíveis. São as camadas de neurônios responsáveis por obter as características do sistema em questão, e realizam praticamente todo o processamento interno da rede.
- Camada de saída: camada responsável por produzir e apresentar os resultados finais do processamento da rede.

Figura 5 - Estrutura de camadas da RNA

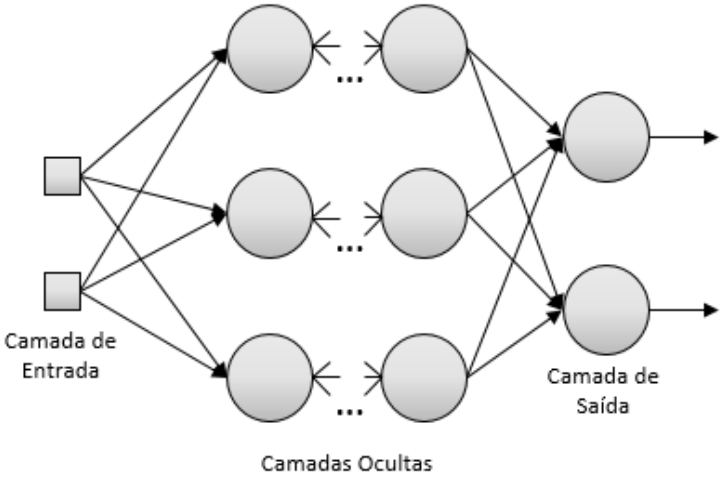

FONTE: Autor

A arquitetura de uma RNA, por sua vez, está relacionada à disposição de suas camadas de neurônios e às interligações entre eles, e influencia no algoritmo de treinamento da rede. Para cada tipo de aplicação desejada, há arquiteturas que melhor se adequam, viabilizando melhores resultados. Há, em termos gerais, quatro principais arquiteturas:

3.2.3.1 Arquitetura *Feedforward* de Camada Simples

Constituída pela camada de entrada e uma única camada de neurônios que é a própria camada de saída. O fluxo de informações é unidirecional e segue da camada de entrada para a camada de saída (Figura 6).

São aplicadas, geralmente, em problemas que envolvem classificação de padrões e filtragem linear.

3.2.3.2 Arquitetura *Feedforward* de Camadas Múltiplas

Constituída pelas camadas de entrada e de saída e por uma ou mais camadas ocultas, sendo a complexidade do problema o principal determinante da quantidade das camadas escondidas e de neurônios. Como na arquitetura *Feedforward*, o fluxo de informações é unidirecional, seguindo da camada de entrada para a de saída (Figura 7).

São aplicadas para problemas de aproximação de funções, classificação de padrões, controle de processos, otimização, entre outras aplicações que envolvem mapeamento não linear entre a entrada e a saída.

3.2.3.3 Arquitetura Recorrente ou Realimentada

Podem ser de camada simples ou múltipla, no entanto, caracteriza-se por possuir pelo menos um laço de realimentação, ou seja, possui entradas de neurônios que são realimentadas com as saídas de outros neurônios. Tal característica possibilita essa arquitetura a processar sistemas variantes no tempo, com processamento dinâmico de dados (Figura 8).

São aplicadas em previsão de séries temporais, otimização e identificação de sistemas, controle de processos, entre outras aplicações.

3.2.3.4 Arquitetura em Estrutura Reticulada

Caracteriza-se por considerar a disposição espacial dos neurônios da rede, extraindo, dela, características. Nesta arquitetura, a forma com a qual os neurônios estão espacialmente organizados na rede interfere no ajuste de pesos e em limiares do processamento (Figura 9).

São aplicadas em diversos tipos de problema, como em problemas de agrupamento, reconhecimento de padrões, otimização de sistemas, grafos, dentre outros.

Figura 6 - Arquitetura *Feedforward* Camada Simples

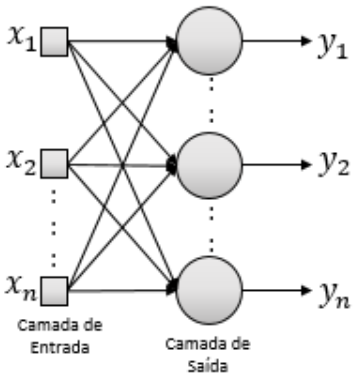

FONTE: Autor

Figura 7 - Arquitetura Feedforward Camadas Múltiplas

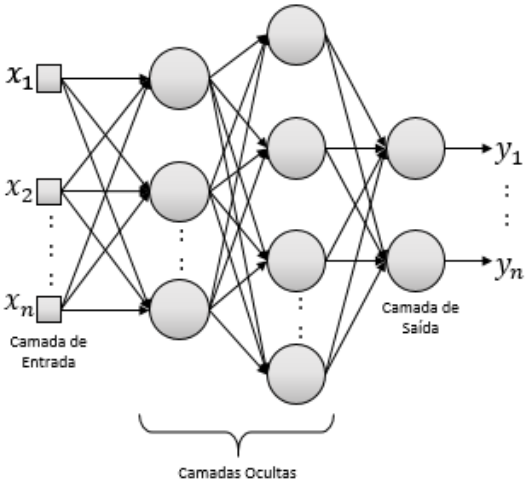

FONTE: Autor

Figura 8 - Arquitetura Realimentada

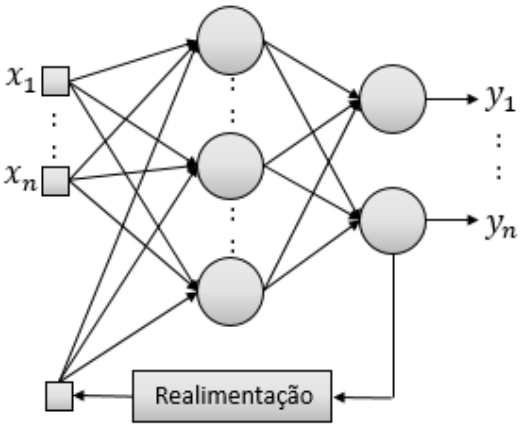

FONTE: Autor

Figura 9 - Arquitetura em Estrutura Reticulada

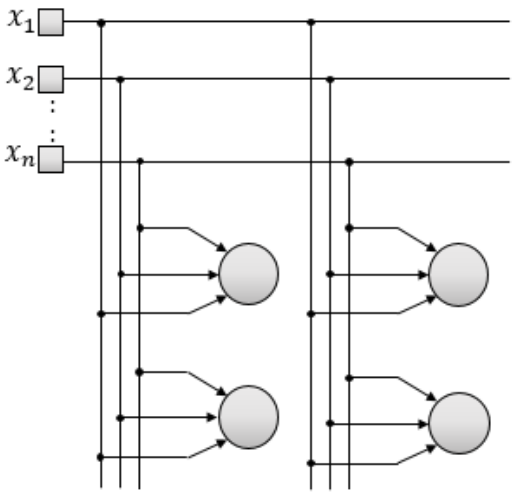

FONTE: Autor

3.2.4 BENEFÍCIOS DA APLICAÇÃO DE RNA

Silva, Spatti e Flauzino (2010) apontam como benefícios obtidos com a aplicação de RNA as seguintes características:

- Adaptação por Experiência: a própria rede ajusta seus parâmetros internos a partir da apresentação sucessiva de amostras e medidas.
- Capacidade de Aprendizado: a aplicação de método de treinamento torna a rede capaz de obter o relacionamento entre as variáveis da aplicação.
- Habilidade de Generalização: com o treinamento, a rede aprende a generalizar o conhecimento adquirido, tornando-se capaz de estimar soluções antes desconhecidas.
- Organização de Dados: a rede é capaz de agrupar amostra de dados similares, baseando-se em características marcantes do conjunto de informações que tem a respeito do processo.
- Tolerância a Falhas: mesmo com parte de sua estrutura interna sensivelmente corrompida, a rede é um sistema tolerante a falhas devido ao elevado nível de interconexões entre seus neurônios.
- Armazenamento Distribuído: como o conhecimento dentro da rede acontece de forma distribuída entre seus neurônios, o sistema torna-se robusto mesmo em casos de eventuais neurônios que se tornarem inoperantes.
- Facilidade de Prototipagem: a maioria das arquiteturas de RNA pode ser facilmente prototipada em *hardware* ou em *software*.

3.3 ESTIMADOR NEURAL

Para o presente trabalho, foi determinada a utilização da arquitetura de rede *Feedforward* de camadas múltiplas, conforme apresentada na Figura 7. Para a implementação da rede foi utilizada a plataforma MATLAB, que apresenta um *toolbox* de redes neurais artificial com uma série de funções que permitem a criação de RNA, treinamento e análise de resultados de uma forma simples e eficiente.

Para treinamento da rede foi aplicado o processo de Treinamento Supervisionado, que consiste em prover a rede com as amostras de entrada e suas respectivas amostras de saída. O processo de aprendizagem da rede se dá através da comparação entre os resultados por ela obtidos e os resultados almejados que foram providos. Os algoritmos de treinamento utilizados aplicam a técnica de *backpropagation*, a qual consiste no ajuste dos pesos sinápticos e limiares após o processamento de cada pacote de amostras. A descrição detalhada da construção e treinamento da RNA é feita na Seção 4.4 deste documento.

4 METODOLOGIA PARA ESTIMAÇÃO DOS INDICADORES

4.1 INTRODUÇÃO

A estimação dos indicadores regulados, DEC e FEC dos conjuntos elétricos ANEEL, é uma prática comum das distribuidoras de energia, uma vez que a previsão do desempenho futuro de tais indicadores não apenas provê à empresa o panorama esperado no que concerne a fiscalização do órgão regulador, mas também oferece oportunidades de realização de medidas preventivas em locais cuja tendência dos indicadores é de piora.

Nesse contexto, o presente trabalho propõe o treinamento de redes neurais artificiais objetivando a estimação dos indicadores de continuidade DEC e FEC de conjunto elétrico ANEEL. Para tal, foram utilizados dados reais de uma distribuidora de energia da região Sudeste do Brasil, referentes ao período de tempo dos anos de 2011 a 2016. Tais dados foram obtidos no banco de dados da área de Qualidade do Sistema, que é a área responsável pela geração e retenção de todos os registros referentes aos indicadores de continuidade do fornecimento. Os dados procedem dos registros das ordens de atendimentos emergenciais realizados pela empresa e da base de registro dos indicadores de continuidade. Foi utilizado o banco de dados Access para melhor manuseio e extração dos dados pertinentes ao projeto.

No decorrer deste capítulo serão apresentadas as premissas do projeto, as delimitações de escopo, a metodologia de pré-processamento dos dados e informações obtidas, e as consequentes decisões referentes ao treinamento da RNA. Ressalta-se que o uso de uma ferramenta inteligente oferece a possibilidade de um melhor tratamento matemático dos dados, diminuindo o fator de inferência humana na escolha dos mesmos. A aplicação de RNA possibilita que informações que dificilmente poderiam ser utilizadas conjuntamente em métodos analíticos sejam consideradas variáveis do problema.

4.2 DEFINIÇÃO DE ESCOPO

4.2.1 PREMISSAS DO PROJETO

Para melhor planejamento das ações a serem executadas durante o ano, é de prática que as distribuidoras de energia estimem o desempenho dos indicadores coletivos de continuidade ao longo dos meses.

Neste sentido, o presente projeto propõe a aplicação de RNA para estimação dos indicadores de continuidade – DEC e FEC – de Conjunto Elétrico ANEEL para o horizonte de tempo de 12 (doze) meses: janeiro a dezembro de um determinado ano. A estimação utiliza dados coletados nos anos anteriores, e não há possibilidade de reprocessamento das previsões durante o ano em curso. Assume-se que as previsões serão estimadas ao início de cada ano para melhor direcionamento do planejamento de ações a serem realizadas no decorrer daquele mesmo ano.

Como projeto piloto desta proposta de trabalho, foi selecionado um Conjunto Elétrico de uma distribuidora de energia da região Sudeste do Brasil, aqui referenciado como Conjunto ALFA. Portanto, os dados utilizados para treinamento, testes e validação da RNA são dados reais de um único conjunto elétrico, apurados no período de 2011 a 2016. Entende-se que, por semelhança de caso, a metodologia desenvolvida para a estimação de um único conjunto pode ser aplicada aos demais, desde que respeitadas as individualidades nas análises de dados realizadas.

4.2.2 DESCRIÇÃO DOS DADOS

Para o conjunto ALFA, foram coletados dados dos anos de 2011 a 2016, referentes às ordens de atendimento emergencial realizadas no domínio do conjunto no tempo especificado e às ordens e eventos que tiveram clientes interrompidos. Tais dados compõem dois bancos de dados distintos:

1. Ordens de Atendimento Emergencial: são os dados referentes a todas as ordens de atendimento realizadas pela empresa, quer tenha havido interrupção de energia, quer não. Contém informação de ano, mês e dia em que a ordem foi gerada; identificação da ordem; classe e causa da ordem; a identificação do dispositivo de proteção da rede ao

qual a ordem está relacionada; as datas de conhecimento da ocorrência, despacho da equipe de atendimento, chegada da equipe ao local da ocorrência e conclusão do serviço; se a ordem é uma ordem programada ou não; e se houve interrupção de energia.

2. Ordens e Eventos com clientes interrompidos: são os dados de todos os eventos de interrupção de energia em que houve algum cliente interrompido. Contém informação de ano, mês e dia em que a ordem foi gerada; identificação da ordem; classe e causa da ordem; se é uma ordem programada ou não; identificação dos eventos de interrupção e de restauração de cada ordem; a duração de tempo e a quantidade de clientes interrompidos em cada evento; a identificação dos dispositivos de proteção responsáveis pela interrupção e pela restauração do fornecimento de energia; o DEC e o FEC do evento na base de clientes do conjunto elétrico; e se a ordem é expurgável ou não.

A partir dos dados contidos nesses dois bancos de dados, foram geradas as variáveis para o treinamento da RNA, apurados para períodos diários, conforme descritas a seguir:

- Indicadores DEC e FEC: para o levantamento dos indicadores foram contabilizadas apenas as ordens não expurgáveis, uma vez que se intende prever os indicadores regulamentados.
- Indicadores DEC e FEC programados: valor dos indicadores referente às ordens de serviço programado.
- Quantidade de interrupções de energia: contagem das ordens de atendimento em que houve ocorrência de interrupção de energia. Tal contagem contabiliza as ordens expurgáveis, uma vez que se entende que a quantidade de ordens influi na ocorrência de dias críticos e pode refletir tendências sazonais.
- Quantidade de interrupções de energia programadas: contagem das ordens referentes a interrupções de energia por serviço programado.
- Quantidade de ordens de atendimento sem interrupção de energia: contagem das ordens de atendimento em que não houve interrupção do fornecimento de energia. Entende-se que tais ordens demandam equipes e que a indisponibilidade dessas equipes para atender ordens em que de fato ocorreram interrupções pode ocasionar aumento do tempo de atendimento destas, influenciando o DEC.

- Tempo médio de atendimento: média do tempo entre o horário de conhecimento da ocorrência e o horário de conclusão do serviço realizado em campo das ordens de atendimento realizadas.
- Tempo médio de preparo: média do tempo entre o horário de conhecimento da ocorrência e o horário em que a equipe responsável pelo serviço sai para o atendimento, das ordens realizadas, ou seja, tempo médio demandado para o despacho de equipe.
- Tempo médio de deslocamento: média do tempo entre o horário do despacho da equipe e o horário em que a mesma chega ao local de realização do serviço das ordens de atendimento realizadas, ou seja, tempo médio do deslocamento de equipes.
- Tempo médio de reparo: média do tempo demandado para realização do serviço das ordens de atendimento realizadas.
- Quantidade de ordens relacionadas a uma determinada causa: contagem das ordens de atendimento em que houve interrupção de energia relacionada a uma causa específica.
- Indicadores DEC e FEC das ordens relacionadas a uma determinada causa: valor dos indicadores referente a ordens de atendimento em que houve interrupção de energia relacionada a uma causa específica.

4.2.3 IDENTIFICAÇÃO DAS VARIÁVEIS INICIAIS DO SISTEMA

4.2.3.1 Seleção das variáveis de Causa de interrupção

Como abordado na Seção 4.2.2, três das variáveis geradas inicialmente relacionam-se à causas (fator gerador) da interrupção. O Anexo II do PRODIST – Módulo 8, Seção 8.2, Revisão 8 – prevê 34 (trinta e quatro) detalhes de fatores geradores de interrupção, categorizados em 8 (oito) grupos de causa, divididos, ainda, por tipo e origem, podendo esses fatores serem expandidos em número, desde que mantidos todos os previstos no procedimento. Cada ordem de interrupção, portanto, possui um fator gerador associado a ela. Visto que a quantidade de fatores geradores é elevada e entendendo que há fatores de maior e de menor impacto dependendo da região em análise, foram selecionadas as causas de maior relevância para o conjunto ALFA, objeto deste estudo.

Para tal, foram levantadas as seguintes informações referentes ao período anual dos anos de 2011 a 2016:

- Quantidade de ordens de interrupção por causa
- DEC por causa
- FEC por causa

As informações coletadas foram, então, ranqueadas e selecionou-se as 5 (cinco) principais causas de interrupções para cada um dos anos e foram obtidos os gráficos Gráfico 1, Gráfico 2 e Gráfico 3. A partir desses 3 (três) gráficos, foram selecionadas as 3 (três) principais causas de cada um deles:

- Gráfico 1: selecionadas as causas conexão, deterioração de equipamento e causas não determinadas.
- Gráfico 2: selecionadas as causas serviço programado com aviso, papagaio (pipa) e deterioração de equipamento.
- Gráfico 3: selecionadas as causas papagaio (pipa), causa não determinadas e deterioração de equipamento.

A partir da seleção das principais 3 (três) causas de cada gráfico, foram determinados os fatores geradores (causas) a serem utilizados como variáveis do sistema. Uma vez que a causa 'Serviço programado com aviso' é equivalente às informações das variáveis referentes a interrupções programadas (Seção 4.2.2) tal causa foi desconsiderada do presente levantamento de variáveis. Portanto, são variáveis do sistema as causas segundo o Quadro 2:

Quadro 2 - Fatores Geradores selecionados como variáveis

SIGLA	CAUSA
C1	Papagaio (pipa)
C2	Deterioração de equipamento
C3	Conexão
C4	Causas não determinadas

FONTE: Autor

Gráfico 1 - 5 Principais Causas (2011-2016): Quantidade de Ordens de Interrupção por Causa

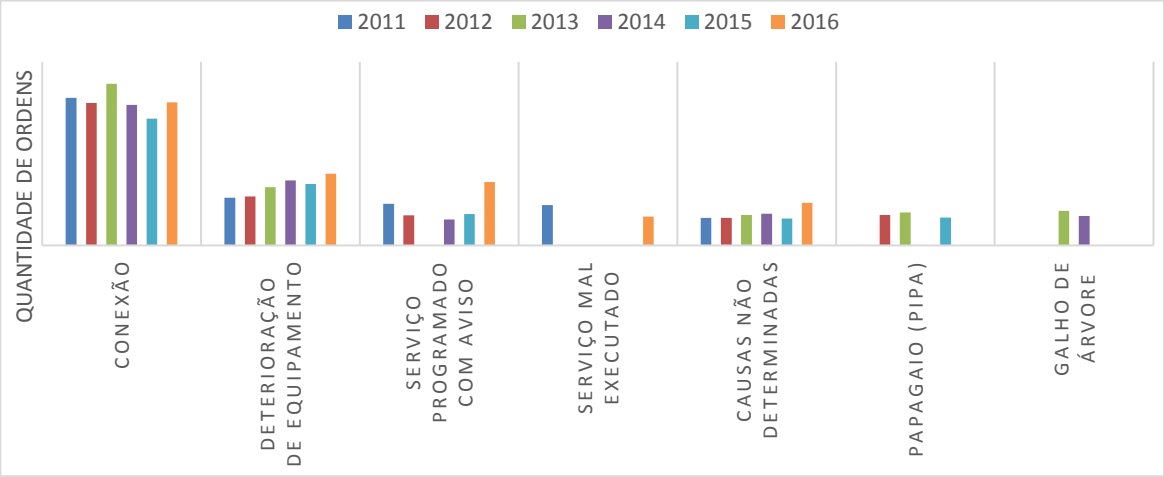

FONTE: Autor

Gráfico 2 - 5 Principais Causas (2011-2016): DEC por Causa

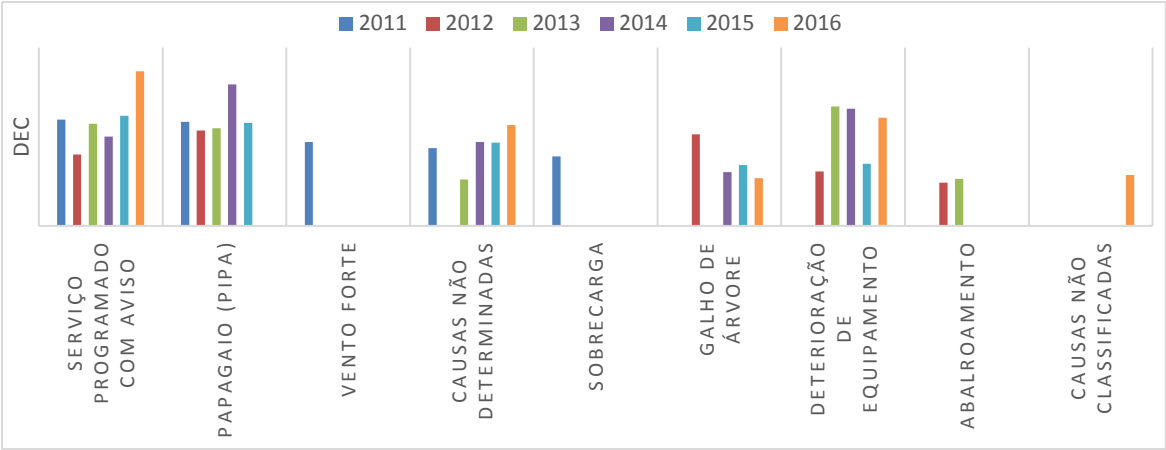

FONTE: Autor

Gráfico 3 - 5 Principais Causas (2011-2016): FEC por Causa

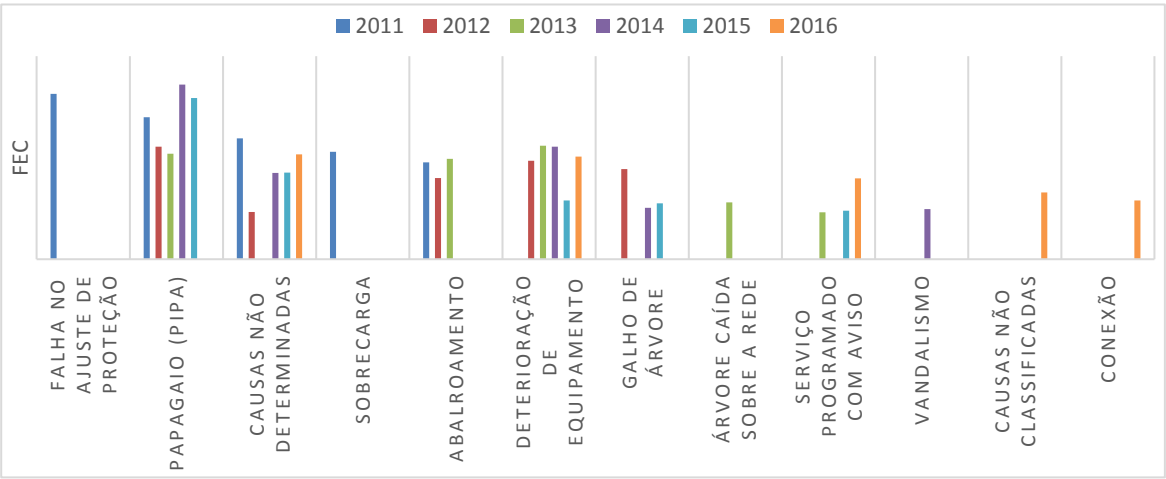

FONTE: Autor

4.2.3.2 Variáveis para análise do DEC

O Quadro 3 apresenta as variáveis que foram estipuladas para a análise das entradas para estimação do indicador DEC. Ressalta-se que todas as variáveis foram apuradas em amostras diárias, para o período de 2011 a 2016.

Quadro 3 - Variáveis para análise do DEC

Sigla	Variável
DEC	Indicador coletivo de continuidade – DEC
DEC_PROG	DEC programado
QTD	Quantidade de interrupções de energia
QTD_PROG	Quantidade de interrupções de energia programadas
QTD_SEMINT	Quantidade de ordens de atendimento sem interrupção de energia
TMA	Tempo médio de atendimento
TMP	Tempo médio de preparo
TMD	Tempo médio de deslocamento
TMR	Tempo médio de reparo
$C1_QTD$	Quantidade de Ordens com Causa Papagaio (Pipa)
$C2_QTD$	Quantidade de Ordens com Causa Deterioração de equipamento
$C3_QTD$	Quantidade de Ordens com Causa Conexão
$C4_QTD$	Quantidade de Ordens com Causas não determinadas
$C1_DEC$	DEC da causa Papagaio (Pipa)
$C2_DEC$	DEC da causa Deterioração de equipamento
$C3_DEC$	DEC da causa Conexão
$C4_DEC$	DEC de causas não determinadas

FONTE: Autor

4.2.3.3 Variáveis para análise do FEC

O Quadro 4 apresenta as variáveis que foram estipuladas para a análise das entradas para estimação do indicador FEC. Ressalta-se que todas as variáveis foram apuradas em amostras diárias, para o período de 2011 a 2016.

Quadro 4 - Variáveis para análise do FEC

Sigla	Variável
$\boldsymbol{FEC}$	Indicador coletivo de continuidade – FEC
$\boldsymbol{FEC_PROG}$	FEC programado
$\boldsymbol{QTD}$	Quantidade de interrupções de energia
$\boldsymbol{QTD_PROG}$	Quantidade de interrupções de energia programadas
$\boldsymbol{C1_QTD}$	Quantidade de Ordens com Causa Papagaio (Pipa)
$\boldsymbol{C2_QTD}$	Quantidade de Ordens com Causa Deterioração de equipamento
$\boldsymbol{C3_QTD}$	Quantidade de Ordens com Causa Conexão
$\boldsymbol{C4_QTD}$	Quantidade de Ordens com Causas não determinadas
$\boldsymbol{C1_FEC}$	DEC da causa Papagaio (Pipa)
$\boldsymbol{C2_FEC}$	DEC da causa Deterioração de equipamento
$\boldsymbol{C3_FEC}$	DEC da causa Conexão
$\boldsymbol{C4_FEC}$	DEC da causa Serviço programado com aviso

FONTE: Autor

4.3 ANÁLISE E PRÉ-PROCESSAMENTO DOS DADOS

Selecionadas as variáveis iniciais para a estimação dos indicadores, o pré-processamento dos dados tem como objetivo levantar as características que importam para o sistema, de cada variável, a fim de analisar – através de recursos matemáticos – sua relevância para o resultado pretendido.

Riqueza de dados não implica riqueza de informação, e para um melhor desempenho e resultado do sistema, busca-se oferecer à rede a maior quantidade disponível de informação sintetizadas no menor número de variáveis possível. Nesse sentido, esta seção apresenta a metodologia aplicada no pré-processamento das variáveis previamente selecionadas para a definição das variáveis de entrada da RNA.

4.3.1 ANÁLISE DE CORRELAÇÕES DOS DADOS

Selecionadas as variáveis iniciais do sistema (Seção 4.2.3), tais dados foram submetidos a um pré-processamento, a fim de filtrar apenas os dados mais relevantes para o desempenho do sistema.

4.3.1.1 Análise do padrão de correlação entre amostras e atrasos

Inicialmente, os dados foram analisados para períodos de apuração mensal. Primeiramente, foram gerados gráficos da correlação cruzada entre as séries temporais das variáveis apresentadas nas páginas 48 e 47 e a série temporal do indicador ao qual tais variáveis se referem. Para os cálculos das correlações, foi utilizado o coeficiente de correlação tau de Kendall – por ser um teste não paramétrico de correlação da posição da amostra – e objetivou-se obter a medida da similaridade entre duas séries em função de um atraso aplicado. Foi, então, levantado o perfil de correlação entre as séries das variáveis e indicadores para cada amostra mensal do ano de 2016, e verificou-se que não há alteração do padrão de correlação entre os atrasos e as amostras presentes. Ou seja, a correlação da amostra presente com as amostras passadas é invariante em relação ao tempo, não havendo particularidades entre os meses analisados. Dessa forma, qualquer amostra das séries pode ser analisada de maneira semelhante em relação aos atrasos. A Figura 10 é um exemplo dos resultados obtidos, e apresenta a correlação entre o DEC e a quantidade de interrupções mensais de 2016.

Figura 10 - Correlação cruzada entre DEC e Quantidade de Interrupções mensais

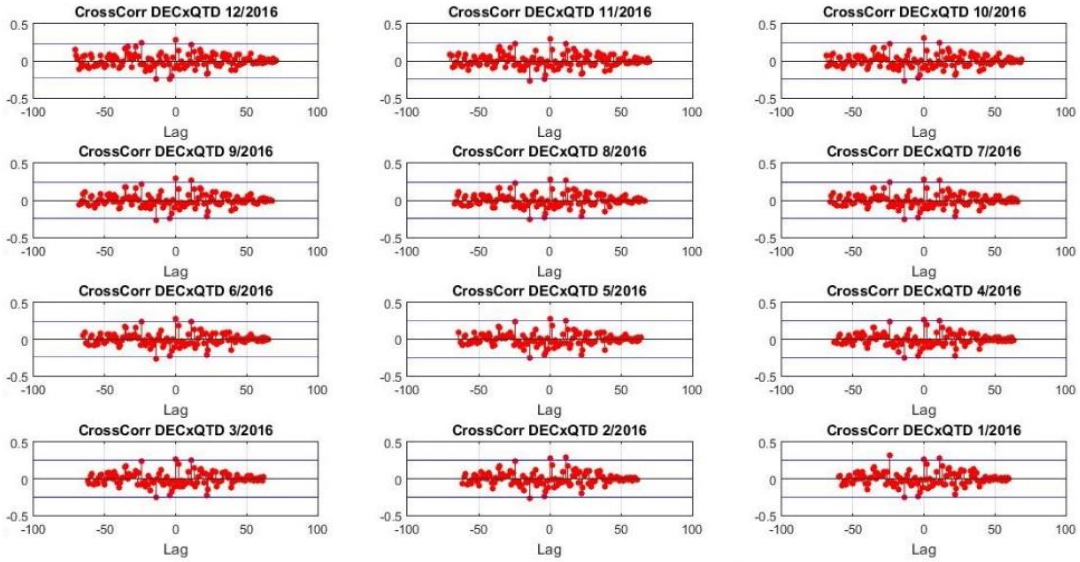

FONTE: Autor.

4.3.1.2 Análise de variáveis através de Intervalo de Confiança e Correlação

Traçados todos os gráficos de correlação cruzada entre as variáveis da Seção 4.2.3 e seus respectivos indicadores, e traçados também os gráficos de auto correlação dos próprios indicadores, obteve-se, então, a relação entre cada uma das séries temporais de variáveis selecionadas para o sistema e a saída desejada.

A primeira condição de seleção das variáveis de entrada da RNA foi que as variáveis selecionadas deveriam ter correlação com a saída maior que um limite mínimo relacionado a um valor predeterminado de intervalo de confiança. Foi definido o limiar de seleção o equivalente a aproximadamente 98% de Confiança – segundo o coeficiente de correlação linear de *Pearson* – e foram selecionadas as variáveis cujas amostras superaram, visualmente, o limiar de Confiança estabelecido, sendo eliminadas aquelas cujas maiores amostras ficaram ao nível do limitar ou abaixo. A Figura 11 e a Figura 12 apresentam os gráficos das correlações cruzadas entre as variáveis iniciais do sistema (descritas em 4.2.3) e seus respectivos indicadores. As tabelas Tabela 1 e Tabela 2 apresentam a correlação entre as variáveis que atenderam ao critério de Confiança estabelecido. Com intuito de eliminar informações redundantes, foram eliminadas variáveis com correlação superior a um limiar de 0,5. As informações em negrito nas tabelas

destacam os pares de variáveis com correlação superior ao limiar estabelecido, e, portanto, apenas uma variável do par foi considerada variável de entrada do sistema.

Figura 11 - Correlação das variáveis pré-selecionadas em relação ao DEC

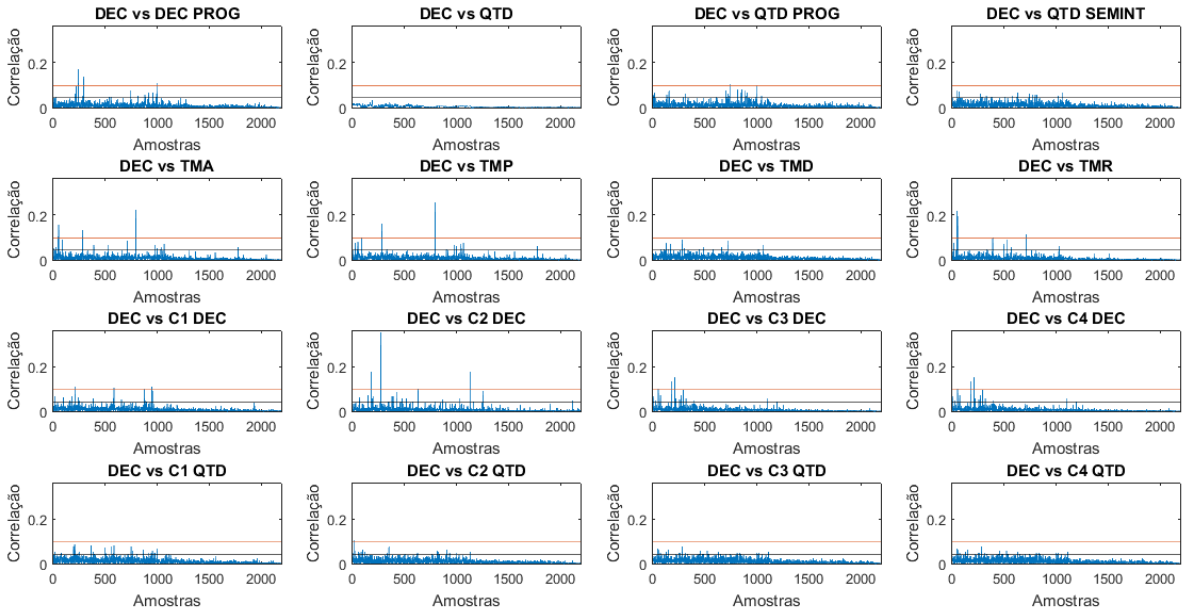

FONTE: Autor.

Figura 12 - Correlação das variáveis pré-selecionadas em relação ao FEC

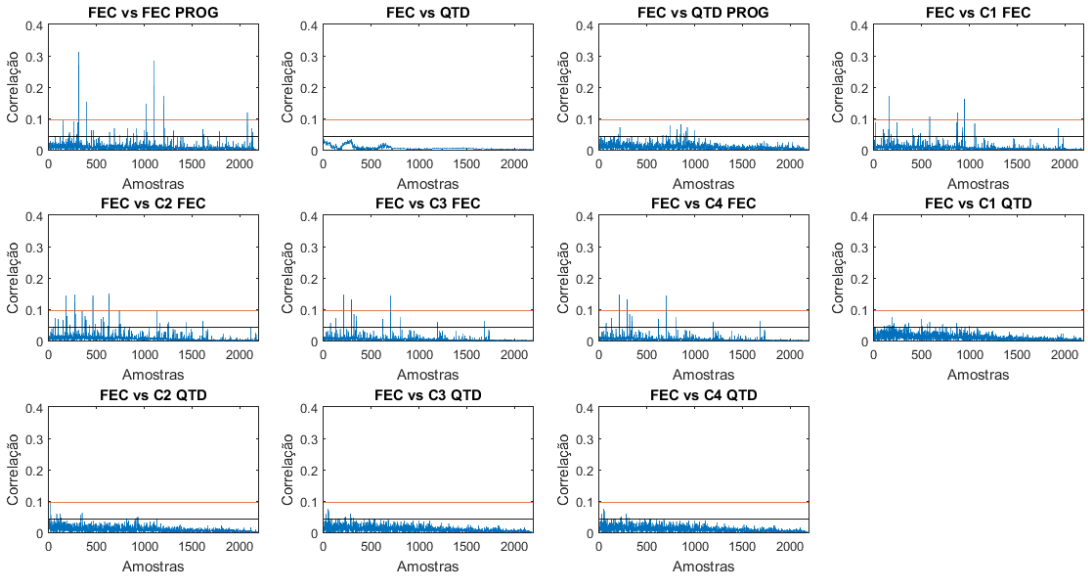

FONTE: Autor.

Tabela 1- Correlação das variáveis de DEC

	DEC PROG	TMA	TMP	TMR	C2 DEC	C3 DEC	C4 DEC
DEC PROG	1	0,0472	-0,0003	0,1214	0,0329	-0,0119	-0,0119
TMA	0,0472	1	**0,8708**	**0,5877**	0,0353	0,0985	0,0985
TMP	-0,0003	**0,8708**	1	0,1225	0,0176	0,0708	0,0708
TMR	0,1214	**0,5877**	0,1225	1	0,0503	0,0846	0,0846
C2 DEC	0,0329	0,0353	0,0176	0,0503	1	0,0790	0,0790
C3 DEC	-0,0119	0,0985	0,0708	0,0846	0,0790	1	**1**
C4 DEC	-0,0119	0,0985	0,0708	0,0846	0,0790	**1**	1

FONTE: Autor

Tabela 2 - Correlação das variáveis de FEC

	FEC PROG	C1 FEC	C2 FEC	C3 FEC	C4 FEC
FEC PROG	1	-0,0193	0,0021	0,0092	0,0092
C1 FEC	-0,0193	1	0,0056	-0,0020	-0,0020
C2 FEC	0,0021	0,0056	1	-0,0012	-0,0012
C3 FEC	0,0092	-0,0020	-0,0012	1	**1**
C4 FEC	0,0092	-0,0020	-0,0012	**1**	1

FONTE: Autor

4.3.2 IDENTIFICAÇÃO DAS VARIÁVEIS DE ENTRADA DO SISTEMA

Após selecionadas as variáveis que apresentam correlação com a saída maior que o limiar determinado para o Intervalo de Confiança e após filtrá-las eliminando as variáveis consideradas informação redundante (conforme apresentado na seção 4.3.1.2), foram analisados mais uma vez os gráficos de correlações das séries temporais, porém, agora, com o objetivo de localizar os atrasos que possuem alta correlação com a amostra presente a fim de determina-los variáveis de entrada da rede.

Novamente foi utilizado o Intervalo de Confiança como limiar para selecionar as amostras desejadas. Em um primeiro momento, foi mantido o limiar de 98% de confiança e foram selecionados os atrasos ao longo de toda a série temporal que atendessem a esse limiar. No entanto, observou-se que foram selecionados atrasos muito grandes, limitando

significativamente a amostra de dados utilizada para treinamento da rede, o que resultou em um resultado não satisfatório: a rede não produzia variância. Para, então, possibilitar um maior volume de amostras para o treinamento da rede, alterou-se o limiar de confiança para o equivalente a 95% (a linha preta das figuras Figura 11 e Figura 12 equivalem ao Intervalo de Confiança de 95%), e restringiu-se o atraso máximo a 365 amostras – equivalente a dados referentes a um período de um ano passado. Tal restrição de atraso máximo permitiu que fossem utilizados dados referentes ao período de 5 (cinco) anos – 2012 a 2016 – para o treinamento e validação da rede. Dessa forma, para a estimação dos indicadores de um determinado ano, são utilizados dados referentes ao ano imediatamente anterior.

Por fim, foram obtidas as variáveis de entrada da RNA. Tais variáveis consistem, portanto, em atrasos predeterminados das séries temporais analisadas em 4.3.1.2, além de atrasos da série temporal do próprio indicador, selecionados a partir do critério de Intervalo de Confiança e de atraso máximo. Portanto, as variáveis selecionadas em cada série temporal não são atrasos necessariamente consecutivos, mas sim aqueles que atendem às exigências determinadas. Foi decidido pelo uso de amostras diárias como entradas da RNA, devido ao maior volume de dados e, consequentemente, melhor desempenho de seu treinamento e resultados. Os quadros Quadro 5 e Quadro 6 apresentam as variáveis que compuseram a matriz de entrada da RNA para cada indicador.

Quadro 5 - Variáveis para a estimação do DEC

SÉRIE TEMPORAL	QUANTIDADEDE ATRASOS UTILIZADOS
DEC	12
DEC_PROG	14
TMA	14
C2_DEC	9
C3_DEC	11
TOTAL DE VARIÁVEIS	**60**

FONTE: Autor

Quadro 6 - Variáveis para a estimação do FEC

SÉRIE TEMPORAL	QUANTIDADE DE ATRASOS UTILIZADOS
FEC	14
FEC_PROG	7
C1_FEC	7
C2_FEC	11
C3_FEC	7
TOTAL DE VARIÁVEIS	**46**

4.4 CONSTRUÇÃO DA REDE NEURAL ARTIFICIAL

Tendo sido selecionadas as variáveis de entrada da rede e tendo a estruturação dos dados para treinamento, teste e validação, foi desenvolvido um código na plataforma MATLAB para treinamento da RNA para estimação dos indicadores DEC e FEC. A Figura 13 apresenta o fluxograma do código desenvolvido.

Como ajustes de parâmetros da rede, é escolhido o indicador a ser estimado, é determinado o algoritmo de treinamento e a função de ativação de cada camada a serem utilizados, é definida a quantidade de camadas da rede e o número mínimo e máximo de neurônios por camada. O código cria, treina e testa 10 (dez) redes para cada combinação de quantidade de neurônios e de quantidade de camadas predeterminadas. Para seleção da rede com melhor resultado, o código utiliza como critério o menor erro quadrático médio do teste de rede. Foi adotado 70% dos dados para treinamento da RNA, 15% para teste e 15% para validação.

Figura 13 - Fluxograma do código de treinamento da RNA

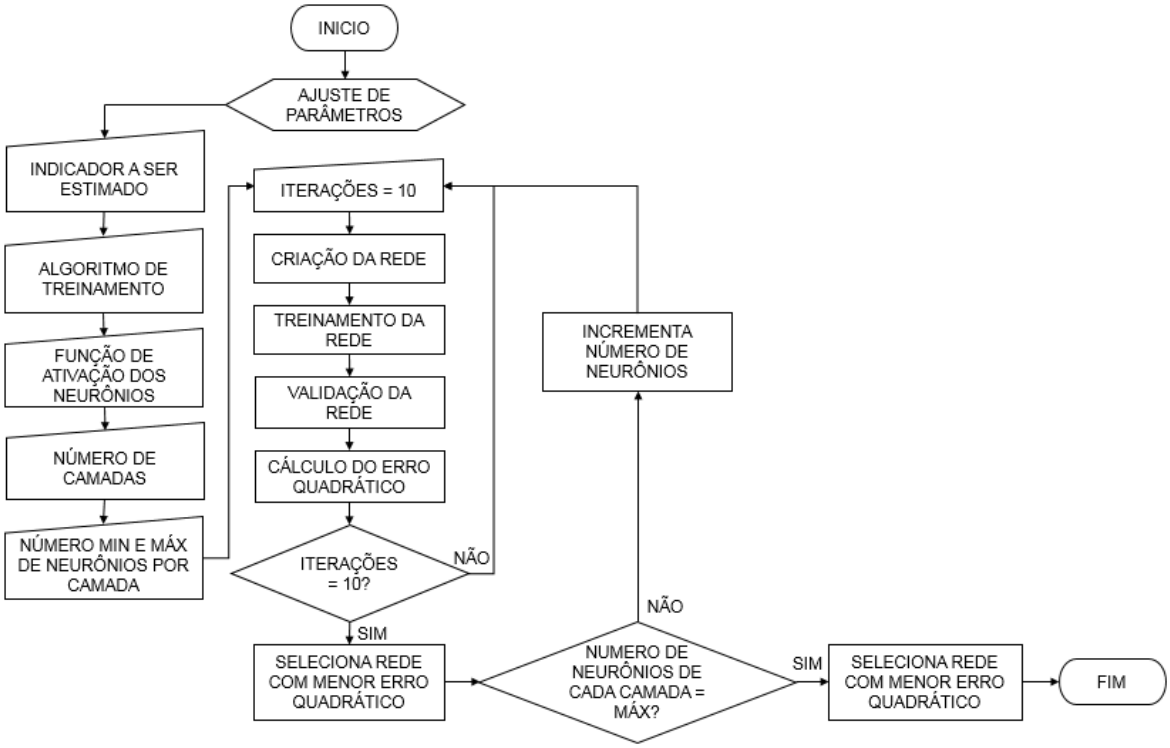

FONTE: Autor

Foram mantidas as configurações padrão do MATLAB para critério de parada do treinamento, que analisa o ganho de aprendizado e interrompe o treinamento após 6 (seis) iterações em que não há melhora de desempenho da rede (erros de validação). Para os algoritmos de treinamento, foram utilizados o de *Levenberg-Marquardt* e o *BFGS quasi-Newton*, sendo ambos métodos de *backpropagation*. Para a função de ativação de cada camada também foi mantida a configuração padrão do MATLAB, que é função de ativação sigmóide. Para o treinamento da rede, foi feito normalização dos dados de entrada, segundo seus mínimos e máximos.

Para determinação da RNA de estimação dos indicadores foram feitos vários treinamentos de redes, alterando a quantidade de camadas ocultas e de neurônios por camada, através do processo de tentativa e erro. Para o número de camadas testadas, restringiu-se ao número máximo de 5 (cinco) camadas ocultas. Para a quantidade de neurônios por camadas, variou-se de 5 (cinco) a 40 (quarenta), dependendo do teste realizado.

5 RESULTADOS

5.1 INTRODUÇÃO

Este capítulo objetiva a apresentação dos resultados obtidos a partir da metodologia exposta no Capítulo 4. Como explanado anteriormente, 70% das amostras totais foram utilizadas no treinamento da RNA e 15% dos dados foram aplicados para seleção da rede com melhor desempenho, pautado no menor erro quadrático médio. Para obtenção dos resultados apresentados neste capítulo, foram aplicados os 15% restantes das amostras totais, separadas especificamente para teste do modelo escolhido.

Ao final dos treinamentos e testes propostos no capítulo anterior, foram selecionadas as RNA que ofereceram os melhores resultados para cada indicador. As figuras Figura 14 e Figura 15 apresentam o esquemático das redes selecionadas, e o Quadro 7 apresenta os principais parâmetros de suas configurações de treinamento e validação.

É apresentado também um resultado comparativo em relação à metodologia de estimação adotada pela distribuidora de energia que forneceu os dados deste trabalho. O processo de estimação por eles empregado consiste em compor os dias do mês ainda por acontecer com os indicadores dos dias equivalentes do ano anterior. Dessa forma, para um mês futuro, a previsão baseia-se apenas nos valores observados no ano anterior. É importante destacar que a empresa estima apenas os indicadores globais, ou seja, referentes à base total de clientes, não havendo previsão equivalente à proposta neste trabalho – dos indicadores mensais de conjuntos elétricos – sendo a metodologia aqui desenvolvida algo ainda não observado dentro da empresa. No entanto, por analogia, o método de estimação utilizado na distribuidora será aplicado no escopo proposto por este projeto para efeito de comparação dos resultados dos métodos.

Quadro 7 - Parâmetros das RNA de estimação dos indicadores

	DEC	**FEC**
Quantidade de Camadas Ocultas	3	2
Quantidade de Neurônios	7/7/7	5/15
Tipo de treinamento	Levenberg-Marquardt	Levenberg-Marquardt
Erro Quadrático Médio da Validação	$2{,}8443\text{x}10^{-4}$	$13\text{x}10^{-4}$

Figura 14 - Arquitetura da RNA de estimação do DEC

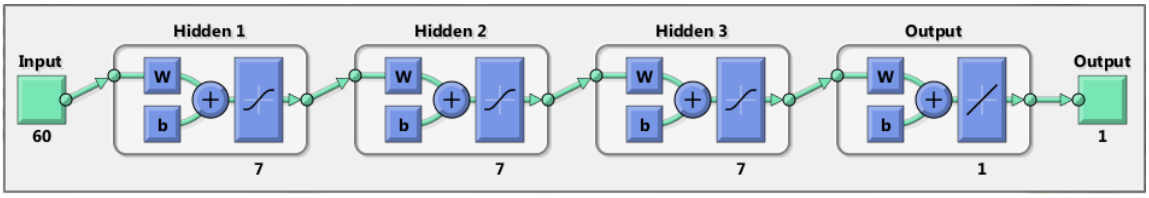

FONTE: Autor

Figura 15 - Arquitetura da RNA de estimação do FEC

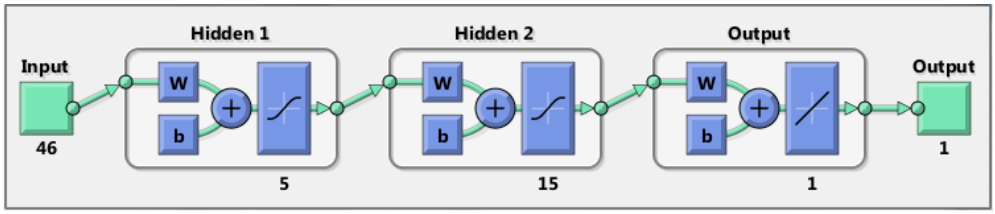

FONTE: Autor

5.2 ESTIMAÇÃO DOS INDICADORES

5.2.1 RNA DE ESTIMAÇÃO DO DEC

Uma vez validada a topologia de rede selecionada para a estimação do indicador DEC, foi obtido o erro quadrático médio do teste para análise de seu desempenho. O Quadro 8 apresenta os valores dos erros quadráticos observados no treinamento da rede, na validação realizada, no teste do modelo e o erro apresentado pelo método de estimação da distribuidora. Observa-se que, embora o erro apresentado no treinamento seja significativo, a rede foi capaz de apresentar respostas com erros consideravelmente inferiores na validação e no teste, e quando comparado ao erro apresentado pelo método da distribuidora, a RNA desenvolvida através da metodologia abordada neste trabalho apresenta resultados com erro significativamente inferior – cerca de 60% menor – sendo justificável sua aplicação. A Figura 16 apresenta a resposta da RNA selecionada para estimação do DEC enquanto a Figura 17 apresenta o resultado da estimação quando aplicado o método da distribuidora, para os dados de teste da rede.

Quadro 8 - Erros quadráticos médios dos resultados do modelo DEC

Erro Treinamento	Erro Validação	Erro Teste	Erro Modelo Distribuidora
$12x10^{-4}$	$2{,}8443x10^{-4}$	$5{,}7429x10^{-4}$	$14x10^{-4}$

FONTE: Autor

Figura 16 - Resultado da RNA para estimação do DEC

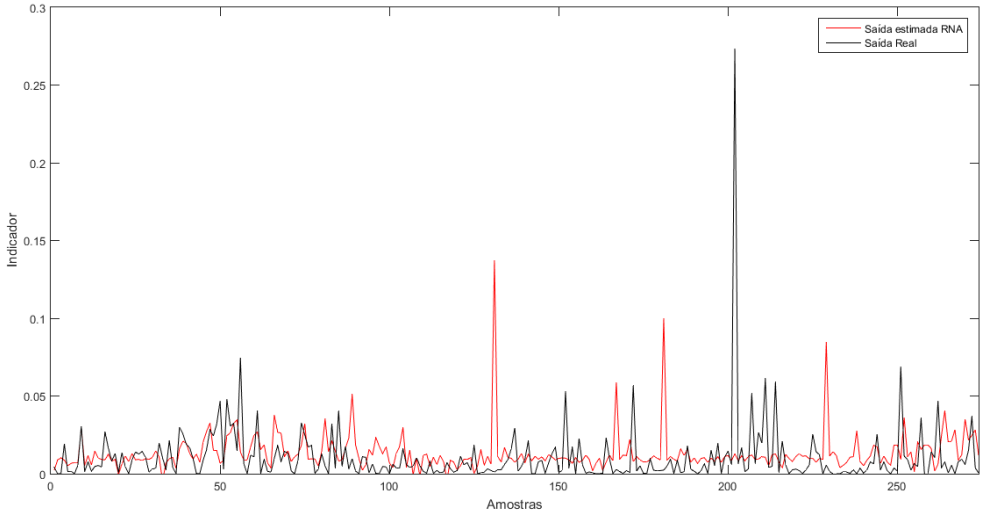

FONTE:Autor

Figura 17 – Resultado do método de estimação da Distribuidora para o DEC

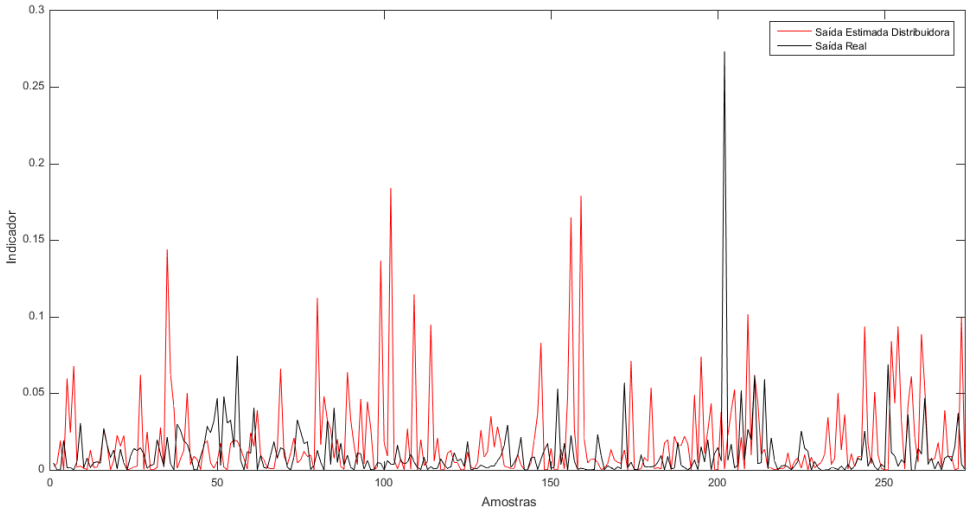

FONTE: Autor.

5.2.2 RNA DE ESTIMAÇÃO DO FEC

Validada a topologia de rede selecionada para a estimação do indicador FEC, foi obtido o erro quadrático médio do teste para análise do desempenho. O Quadro 9 apresenta os valores dos erros quadráticos observados no treinamento da rede, no teste realizado, na validação do modelo e o erro apresentado pelo método de estimação da distribuidora. Observa-se que não houve grande variação nos valores dos erros obtidos com o treinamento, validação e teste. Quando observada, ainda, a Figura 18, que apresenta a saída da RNA para a estimação do indicador

FEC (para os dados de teste da rede), é possível perceber que a rede não produziu muita variação, indicando a possibilidade de que os dados usados como entrada para o treinamento da rede não tenham sido suficientes para produzir aprendizado e generalização suficientes para a obtenção de uma boa resposta. Quando comparado o erro apresentado no teste da rede com o erro apresentado quando aplicado o método da distribuidora, observa-se que a RNA teve pior desempenho, apresentando erro 20% superior, o que caracteriza um percentual significativo, tornando a aplicação da rede não justificável para a estimação do FEC. No entanto, conforme estabelecido no Quadro 6, as entradas da RNA de estimação do FEC são atrasos das séries temporais do FEC relacionado a três causas distintas, da série temporal relacionada ao FEC programado e atrasos da série temporal do próprio indicador. A consideração de novas variáveis como entrada do modelo poderia agregar informação relevante ao treinamento e aprendizagem da rede, sendo, portanto, uma alternativa para otimização do processo e obtenção de melhores resultados. A Figura 19 apresenta o resultado da estimação quando aplicado o método da distribuidora, para os dados de teste da rede.

Quadro 9 - Erros quadráticos médios dos resultados do modelo FEC

Erro Treinamento	**Erro Validação**	**Erro Teste**	**Erro Modelo Distribuidora**
$6{,}6x10^{-3}$	$1{,}3x10^{-3}$	$1{,}8x10^{-3}$	$1{,}5x10^{-3}$

FONTE: Autor

Figura 18 - Resultado da RNA para estimação do FEC

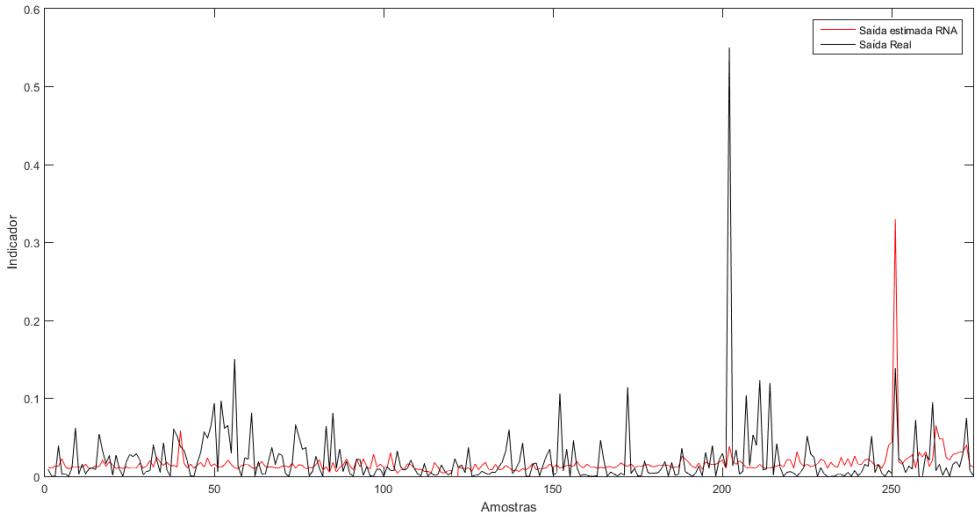

FONTE: Autor.

Figura 19 - Resultado do método de estimação da Distribuidora para o FEC

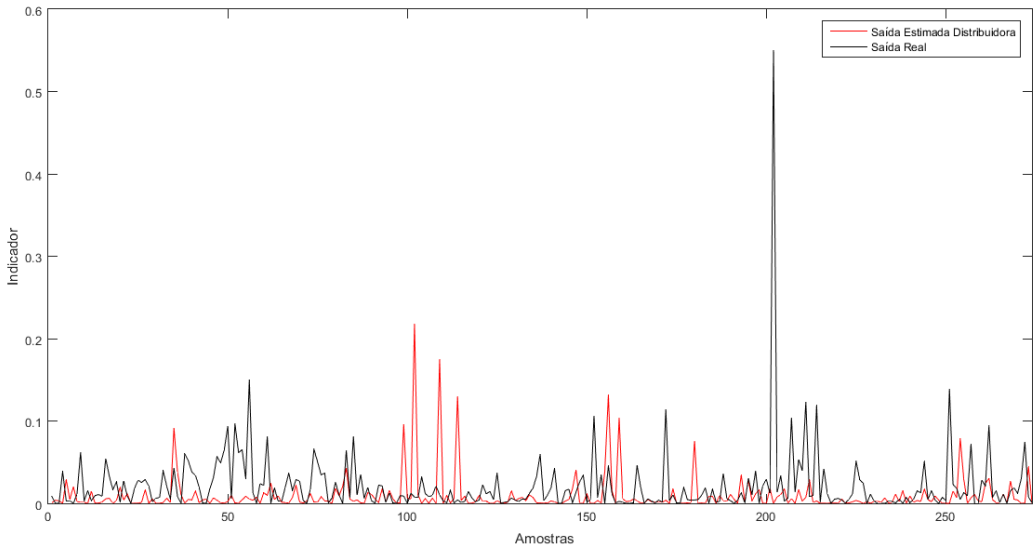

FONTE: Autor.

5.3 CONSIDERAÇÕES FINAIS

Embora os modelos de Redes Neurais Artificiais – e outros sistemas inteligentes – possuam ampla aplicabilidade, adequando-se a diferentes abordagens, quando aplicado a uma determinada finalidade, o modelo assume suas peculiaridades. Dessa forma, tão importante como a escolha da arquitetura e a escolha de parâmetros para a rede, é a metodologia aplicada na seleção de suas informações de entrada e condicionamento dos dados, que serão as informações responsáveis pelo treinamento e aprendizagem do sistema e, consequentemente, pelo desempenho da rede para o objetivo ao qual foi proposta.

A metodologia apresentada no Capítulo 4 buscou selecionar dados que apresentassem maior potencial de informação relevante à finalidade desejada, tal qual eliminar redundâncias de informação com o objetivo de otimizar a performance da rede. No entanto, devido ao grande volume de dados e à complexidade da tratativa dos mesmos, foram estipulados parâmetros para reduzir a quantidade de variáveis. Dessa forma, para uma maior compreensão das limitações da metodologia proposta, uma abordagem mais ampla – com parâmetros de seletividade mais frouxos e considerando maior diversidade de informações e variáveis – deve ser avaliada.

6 CONCLUSÕES E TRABALHOS FUTUROS

6.1 CONCLUSÕES

A previsão dos indicadores de continuidade do fornecimento de energia oferece às distribuidoras de energia a possibilidade de um planejamento melhor direcionado e a possibilidade de ganhos referentes a um melhor desempenho frente às exigências regulatórias. No entanto, a estimação de tais indicadores caracteriza um grande desafio. Várias metodologias foram desenvolvidas e estudadas com o objetivo de alcançar resultados satisfatórios. O trabalho aqui apresentado trouxe uma abordagem heurística por inteligência artificial, através da aplicação de redes neurais artificiais. Foram obtidos resultados satisfatórios para a estimação do DEC – com redução de 60% do erro quadrático médio quando comparados ao método habitual empregado pela distribuidora de energia – e resultados não aplicáveis para a estimação do FEC – com aumento de 20% em relação à mesma metodologia aplicada na empresa.

Para o tratamento de dados, ou pré-processamento, a utilização de intervalos de confiança elevados permitiu uma escolha de variáveis com maior seletividade e análise de correlação entre as variáveis do sistema e as saídas desejadas permitiu a eliminação de informações redundantes contribuindo para a otimização do processamento do sistema. É importante destacar que o presente projeto propõe a estimação de um processo estocástico com alto grau de aleatoriedade, sendo influenciado por fatores de diferentes naturezas, como fatores climáticos, disponibilidade de equipes e de recursos financeiros, taxa de falha de equipamentos, dentre vários outros. Além disso, os dados utilizados na metodologia aqui proposta são informações provenientes apenas do banco de dados da Qualidade do Sistema, sendo, portanto, informações referentes ao processo regulatório de cálculo dos indicadores, não abrangendo, portanto, informações de outras naturezas que são potencialmente relevantes ao processo de aprendizado da rede.

No que concerne à escolha das características do sistema inteligente, é importante destacar que o estudo de metodologia proposta por este trabalho assumiu o uso de uma arquitetura de rede *feedforward* multicamadas, com método de treinamento de *backpropagation*, e limitou-se ao uso dos recursos da plataforma MATLAB. No entanto, há métodos mais recentes de treinamento de sistemas inteligentes e plataformas com recursos diferenciados, além de outras estruturas de rede aplicáveis ao problema proposto, de forma a metodologia proposta pode ser

abordada sob a ótica de diferentes métodos computacionais desenvolvidos para aplicações de sistemas inteligentes. Portanto, os resultados obtidos nesse trabalho podem facilmente ser expandidos a uma análise mais ampla e completa.

6.2 TRABALHOS FUTUROS

Dentre as diversas possibilidades de estender a metodologia aqui proposta – e as possibilidades oferecidas pelo uso de sistemas inteligentes – a aplicações variadas dentro do escopo da Qualidade do Serviço e do Planejamento de Manutenção, pontuam-se as possibilidades de:

- Aplicação de redes neurais artificiais para estimação de taxa de falha de dispositivos de proteção da rede objetivando melhor direcionamento de ações de manutenção;
- Aplicação de redes neurais artificiais na estimação de compensações pela transgressão dos limites de continuidade do fornecimento de energia elétrica.

REFERÊNCIAS BIBLIOGRÁFICAS

ANEEL. Entendendo a Tarifa. **Site da ANEEL**, 2017. Disponivel em: <http://www.aneel.gov.br/entendendo-a-tarifa/-/asset_publisher/uQ5pCGhnyj0y/content/reajuste-tarifario-anual/654800?inheritRedirect=false>. Acesso em: Agosto 2017.

ANEEL. Informações Técnicas. **Site da ANEEL**, 2017. Disponivel em: <http://www.aneel.gov.br/informacoes-tecnicas>. Acesso em: Agosto 2017.

ANEEL. PRODIST - Módulo 8. **Site da ANEEL**, Agosto 2017. Disponivel em: <http://www.aneel.gov.br/modulo-8>. Acesso em: Agosto 2017.

ANEEL. Compensação pela Transgressão dos Limites de Continuidade. **Site da ANEEL**, 2018. Disponivel em: <http://www.aneel.gov.br/indicadores-de-compensacao-de-continuidade>. Acesso em: Janeiro 2018.

ANEEL. PRODIST - Módulo 1. **Site da ANEEL**, 2018. Disponivel em: <http://www.aneel.gov.br/modulo-1>. Acesso em: Janeiro 2018.

ANEEL. Metodologia de Cálculo do Fator X. **Site da ANEEL**. Disponivel em: <http://www2.aneel.gov.br/aplicacoes/audiencia/arquivo/2014/023/resultado/nota_tecnica_fator_x.pdf>. Acesso em: Agosto 2017.

ARAÚJO JR., A. D. **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**. Salvador: [s.n.], 2016.

ARTIFICIAL Intelligence. **TutorialsPoint**, 2017. Disponivel em: <https://www.tutorialspoint.com/artificial_intelligence/index.htm>. Acesso em: Dezembro 2017.

BATISTA, O. E. **Sistema Inteligente baseado em Decomposição por Componentes Ortogonais e Inferência Fuzzy para Localização de Faltas de Alta Impedância em**

Sistemas de Distribuição de Energia Elétrica com Geração Distribuída. São Carlos: [s.n.], 2016.

EWALD, C. A. Práticas de Planejamento e Controle da Evolução dos Indicadores de. **SENDI**, Belo Horizonte, 21 a 25 Agosto 2006.

FGV. Índices Gerais de Preços. **Portal IBRE**, 2018. Disponivel em: <http://portalibre.fgv.br/main.jsp?lumChannelId=402880811D8E34B9011D92B6B6420E96>. Acesso em: Janeiro 2018.

GONTIJO, M. M. **Modelagem e Otimização dos Indicadores de Confiabilidade na Reconfiguração das Redes em Sistemas de Distribuição**. Belo Horizonte: [s.n.], 2007.

HAYKIN, S. **Redes Neurais, Princípios e Práticas**. 2ª. ed. Ontário: Bookman, 2001.

IBGE. Índice Nacional de Preços ao Consumidor Amplo - IPCA e Índice Nacional de Preços ao Consumidor - INPC. **Site do IBGE**, 2018. Disponivel em: <https://ww2.ibge.gov.br/home/estatistica/indicadores/precos/inpc_ipca/defaultinpc.shtm>. Acesso em: Janeiro 2018.

MAGALHÃES, E. F. A. **Modelagem e Simulação de Indicadores de Continuidade:** Ferramenta auxiliar para a manutenção em redes de distribuição de energia elétrica. Salvador: [s.n.], 2017.

PÉREZ, J. P. G. **Qualidade do Serviço de Distribuição de Energia Elétrica:** Indicadores, Limites, Compensações e Incentivos Regulatórios. São Paulo: [s.n.], 2017.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3ª. ed. [S.l.]: Elsevier Editora Ltda, 2010.

SCHWAB, K. The Fourth Industrial Revolution: What It Means and How to Respond. **Foreign Affairs**, 2015. Disponivel em: <https://www.foreignaffairs.com/articles/2015-12-12/fourth-industrial-revolution>. Acesso em: Dezembro 2017.

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais, Curso prático. para Engenharia e Ciências Aplicadas**. São Paulo: Artliber Editora Ltda, 2010.