

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS ARARANGUÁ**

Victor Costa Melo

**GERENCIAMENTO DE FALHAS EM REDES DE
ENERGIA UTILIZANDO REDES NEURAI
ARTIFICIAIS**

Araranguá

2017

Victor Costa Melo

**GERENCIAMENTO DE FALHAS EM REDES DE
ENERGIA UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

Trabalho de Conclusão de Curso submetido à Universidade Federal de Santa Catarina como parte dos requisitos necessários para obtenção de grau em Engenharia de Computação.
Orientadora: Prof. Dr. Analucia Schi-
affino Morales

Araranguá

2017

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Melo, Victor Costa

Gerenciamento de Falhas em Redes de Energia Utilizando
Redes Neurais Artificiais / Victor Costa Melo ;
orientadora, Analucia Schiaffino Morales, 2017.
67 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Campus Araranguá,
Graduação em Engenharia de Computação, Araranguá, 2017.

Inclui referências.

1. Engenharia de Computação. 2. Gerenciamento de Falhas
na Rede de Energia. 3. Redes Neurais Artificiais. 4. Smart
Grids. 5. Falhas na Rede Elétrica Brasileira. I. Morales,
Analucia Schiaffino. II. Universidade Federal de Santa
Catarina. Graduação em Engenharia de Computação. III. Título.

Victor Costa Melo

**GERENCIAMENTO DE FALHAS EM REDES DE ENERGIA
UTILIZANDO REDES NEURAS ARTIFICIAIS**

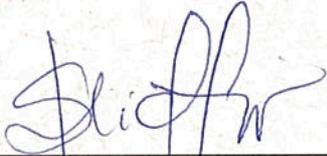
Este trabalho de conclusão foi julgado aprovado para a obtenção do
Título de “Engenheiro de Computação” e aprovado em sua forma final
pela Universidade Federal de Santa Catarina

Araranguá, 04 de dezembro 2017

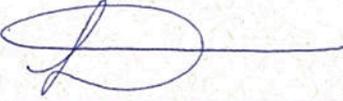


Prof.^a, Dr.^a Eliane Pozzebon
Coordenadora do Curso

Banca Examinadora:



Prof.^a, Dr.^a Analucia Schiaffino Morales
Orientadora



Prof.^a, Dr.^a Luciana Bom Frigo



Prof.^a, Dr.^a Eliane Pozzebon

AGRADECIMENTOS

A esta universidade, seu corpo docente, direção e administração que oportunizaram a janela que hoje vislumbro um horizonte superior, eivado pela acendrada confiança no mérito e ética aqui presentes.

A minha orientadora Prof. Dra. Analúcia Schiaffino Morales, pelo suporte, por suas correções e incentivos.

Ao Prof. Dr. Gustavo Medeiros De Araújo pela oportunidade e apoio na elaboração deste trabalho.

A Prof. Dra. Eliane Pozzebon que foi minha grande incentivadora ao longo da graduação me proporcionando grandes oportunidades de aprendizado, sempre disponível e preocupada com a melhor forma de atender as necessidades acadêmicas, não só minhas como de todo o curso de Engenharia de Computação.

A Prof. Dra. Luciana Bolan Frigo por ter contribuído para minha formação e aceitar compor a banca de avaliação.

Também ao meu colega Luan Casagrande que foi fundamental para elaboração deste trabalho, disponibilizou seu tempo para me ajudar no desenvolvimento da segunda rede neural para classificação das falhas.

Agradeço a todos os professores por me proporcionar o conhecimento não apenas racional, mas a manifestação do caráter e afetividade da educação no processo de formação profissional, por tanto que se dedicaram a mim, não somente por terem me ensinado, mas por terem me feito aprender. A palavra mestre, nunca fará justiça aos professores dedicados aos quais sem nominar terão meus eternos agradecimentos.

Por fim, agradeço a minha mãe Denise, heroína que me deu apoio, incentivo nas horas difíceis, de desânimo e cansaço.

Ao meu pai, Gean que apesar de todas as dificuldades me fortaleceu e que para mim foi muito importante.

A Todos que direta ou indiretamente fizeram parte da minha formação, meu muito obrigado.

Não existe expectativa de vitória sem esforço

Sun Tzu

RESUMO

O presente trabalho versa sobre o gerenciamento de falhas em sistemas de energia utilizando métodos de classificação de falhas na rede elétrica por meio de redes neurais artificiais. Pois a rede elétrica brasileira contém diversos problemas ligados a segurança, estabilidade e confiabilidade. O problema que o trabalho deseja solucionar é como a rede elétrica brasileira pode ser melhorada utilizando conceitos de Smart Grid e um gerenciador de falhas baseado em redes neurais. A resposta para este problema é desenvolver um módulo do gerenciador de falhas: o classificador de falhas baseado em redes neurais artificiais (RNA) empregando os conceitos de Smart Grid para auxiliar na melhora na qualidade da rede elétrica brasileira. Através de pesquisas sobre gerenciamento de falhas, redes neurais, algoritmos genéticos (AG) e Smart Grids foi possível especificar e modelar duas RNAs: uma com arquitetura simples e a outra com: arquitetura, número de camadas e neurônios definido por um algoritmo genético. A partir disso, testar e comparar os resultados obtidos com cada rede. Após análise da bibliografia existente sobre RNAs que utilizaram algoritmos genéticos para encontrar a configuração ótima de uma RNA e comparando com a RNA criada sem a interferência de AG foi demonstrado que a RNA combinada com AG para encontrar a configuração ótima, de acordo com o problema que se quer resolver, foi superior a outra e apresentou resultados satisfatórios na classificação das falhas na rede de energia.

Palavras-chave: *Smart Grids*, gerenciamento de falhas, redes neurais artificiais

ABSTRACT

The present work deals with the management of faults in energy systems using methods of classifying faults in the electric network through artificial neural networks. Because the Brazilian grid contains several problems related to security, stability and reliability. The problem that the work wants to solve is how the Brazilian grid can be improved using Smart Grid concepts and a fault manager based on neural networks. The answer to this problem is to develop a fault manager module: the fault classifier based on artificial neural networks (RNA) employing the concepts of Smart Grid to assist in the best quality of the Brazilian grid. Through researches on fault management, neural networks, genetic algorithms (AG) and Smart Grids, it was possible to specify and model two RNAs: one with architecture based on the empirical mode of creation and the other with its architecture, number of layers and neurons defined by a genetic algorithm. From this, test and compare the results obtained with each network. After analyzing the existing literature on RNAs that used genetic algorithms to find the optimum configuration of an RNA and comparing with the RNA created without the interference of AG, it was demonstrated that the RNA combined with AG to find the optimal configuration according to the problem that is to solve was superior to another and presented satisfactory results in the classification of failures in the power grid.

Keywords: *Smart Grids, fault management, artificial neural networks*

LISTA DE FIGURAS

Figura 1	Modelo Conceitual INPT Fonte: (SANTIS et al., 2015) ..	22
Figura 2	Maiores Blecautes no Mundo Fonte: (SAMADI et al., 2010)	26
Figura 3	Aumento da Utilização de Termelétricas no Brasil Fonte: (SAMADI et al., 2010)	27
Figura 4	Neurônio Artificial Fonte: (RAZA; KHOSRAVI, 2015)	31
Figura 5	Rede MLP Fonte: (DUTRA; SPERANDIO; COELHO, 2004)	32
Figura 6	Aprendizado competitivo para a separação de entradas. Fonte: (TSODYKS; GILBERT, 2004)	34
Figura 7	Diagrama em blocos da aprendizagem com professor Fonte: (HAYKIN, 2001)	35
Figura 8	Reconhecimento de padrões. Fonte: (HAYKIN, 2001) ...	37
Figura 9	Espectro senoidal variando de acordo com as perturbações	41
Figura 10	Representação do circuito fase-terra	42
Figura 11	Representação do circuito fase-fase	42
Figura 12	Representação do circuito fase-fase-terra	43
Figura 13	Representação do circuito fase-fase-terra	43
Figura 14	Modelo do sistema de transmissão	47
Figura 15	Modelo do sistema de transmissão	48
Figura 16	Janela de móvel de Dados Fonte: (DINIZ; SILVA; NETTO, 2014)	49
Figura 17	Representação gráfica do conjunto de classificação	52
Figura 18	Comparação entre a saída desejada e a saída real - teste 1	53
Figura 19	Comparação entre a saída desejada e a saída real - teste 5	54
Figura 20	Indicadores da RNA 1 ao final do 5º teste	54
Figura 21	Indicadores da RNA 2 ao término da validação	55
Figura 22	Erro médio da RNA 2	56

LISTA DE TABELAS

Tabela 1	Parâmetros gerados para definição da arquitetura das RNA.....	49
Tabela 3	Características das duas RNAs utilizadas na classificação de falhas.....	50
Tabela 2	Combinações para as saídas da RNA de classificação...	50
Tabela 4	Indicadores da RNA 1	53
Tabela 5	Parâmetros limítrofes da RNA 2.....	55
Tabela 6	Comparação da performance das RNAs.....	56

SUMÁRIO

1 INTRODUÇÃO	17
1.1 CONTEXTUALIZAÇÃO E PROBLEMÁTICA	17
1.2 OBJETIVOS	18
1.2.1 Objetivo Geral	18
1.2.2 Objetivos Específicos	18
1.3 METODOLOGIA	18
1.4 ORGANIZAÇÃO DO TRABALHO	19
2 SMART GRIDS	21
2.1 DEFINIÇÃO	21
2.2 SISTEMA DE GERENCIAMENTO DE FALHAS	23
2.3 LEVANTAMENTO DE FALHAS NA REDE ELÉTRICA BRASILEIRA	25
3 INTELIGÊNCIA ARTIFICIAL (IA) E GERENCIA- MENTO DE FALHAS	29
3.1 PRINCIPAIS APLICAÇÕES NA ATUALIDADE	29
3.2 REDES NEURAIS ARTIFICIAIS (RNAs)	31
3.3 PROCESSOS DE APRENDIZAGEM	33
3.3.1 Aprendizado Competitivo	33
3.3.2 Classificação com Redes Neurais	36
3.3.3 Perceptrons de Múltiplas Camadas e seu Treina- mento	37
3.4 ALGORITMOS GENÉTICOS EMPREGADOS NA OTI- MIZAÇÃO DA ARQUITETURAS DE RNAs	38
4 FALHAS PRESENTES NO SISTEMA ELÉTRICO ..	39
5 MODELAGEM, SIMULAÇÃO E RESULTADOS	45
5.1 MODELAGEM	45
5.1.1 Dados do vetor de entrada	47
5.1.2 Condições de Curto-Circuito	49
5.2 EXPERIMENTO	50
5.3 RESULTADOS	52
6 CONCLUSÃO E TRABALHOS FUTUROS	57
REFERÊNCIAS	59

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E PROBLEMÁTICA

Existe a necessidade de distribuir a energia produzida nas usinas, seja ela térmica, hidráulica, termo-nuclear, eólica ou solar... até os centros urbanos, onde a energia é de fato consumida. Desta maneira, surge uma demanda pela construção das redes de energia elétrica, esta energia sai de seus geradores passa por cabos revestidos e isolados, presos em grandes postes de metal. À este conjunto dá-se o nome de *Rede de Transmissão de Energia Elétrica* (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2016).

O risco de desligamentos forçados (devido a falhas) na *Rede de Transmissão de Energia Elétrica* é iminente. Um exemplo são os grandes apagões que aconteceram no ano de 2001 e 2002, derivados da falta de planejamento da distribuição de energia e dependência brasileira das hidrelétricas (PINTO,).

No período de 1º de agosto de 2014 a 31 de julho de 2015 a ANEEL - Agência Nacional de Energia elétrica realizou uma análise sobre estas falhas. Nesta análise foram selecionadas 50 linhas de transmissão e 28 subestações, responsáveis por 1.142 desligamentos forçados, o que representou 34 % do total falhas no período. As falhas encontradas estão distribuídas em quatro grandes grupos, são eles: meio ambiente, terceiros (Vandalismo, Queimadas e etc), falha humana, falha em componentes e outros (sobrecarga, baixa tensão de fornecimento, poste podre, chave fraca entre outros) (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2016).

O presente trabalho tem como desafio demonstrar como conceitos de novas tecnologias poderiam auxiliar na melhoria do sistema elétrico brasileiro. Neste caso, através de um sistema de gerenciamento de falhas com o uso de redes neurais artificiais. Considerando que este tema é muito complexo, foram empregadas algumas simplificações para o desenvolvimento do trabalho, restringindo-se os experimentos e buscando apoio nos trabalhos relacionados disponíveis na literatura.

Além disso, no início da elaboração do trabalho foram necessárias reuniões e solicitações de dados para os órgãos públicos estaduais responsáveis pela rede elétrica catarinense. No entanto, os dados não foram disponibilizados, ocasionando algumas limitações no projeto inicial planejado.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Desenvolver um módulo do gerenciador de falhas: o classificador de falhas, baseado em Rede Neurais Artificiais(RNAs) empregando conceitos de Smart Grids para auxiliar na melhora da qualidade da rede de energia brasileira.

1.2.2 Objetivos Específicos

Considerando o desenvolvimento do trabalho e o objetivo geral apresentado, destacam-se os seguintes objetivos específicos:

- Aprofundar os conceitos sobre os Smart Grids e a viabilidade da sua aplicação na rede elétrica brasileira
- Elaborar uma descrição das principais falhas presentes na rede elétrica brasileira
- Testar e comprovar o uso de RNAs para classificar falhas da rede elétrica

1.3 METODOLOGIA

O trabalho foi desenvolvido seguindo as seguintes etapas metodológicas. Consistiu principalmente de pesquisa bibliográfica e experimentos simulados empregando técnicas de RNAs disponíveis na literatura acadêmica. Além disso, foram realizadas entrevistas com engenheiros da CELESC para compreender o funcionamento do sistema elétrico brasileiro, e mais específico na região de Santa Catarina.

- Pesquisa bibliográfica sobre gerenciamento de falhas em *Smart Grids*;
- Compreender o funcionamento do sistema elétrico brasileiro, com ênfase na região sul do Brasil;
- Fazer um levantamento das principais falhas do sistema elétrico brasileiro;

- Buscar uma base de dados e modelar a arquitetura de uma RNA;
- Realizar testes na RNA;
- Testar outras RNAs mais otimizadas, empregar uso de algoritmos genéticos para a otimização de parâmetros na rede;
- Analisar os resultados obtidos através de métricas de desempenho de RNAs;
- Propor melhorias e outras questões relacionadas ao problema.

1.4 ORGANIZAÇÃO DO TRABALHO

O trabalho está organizado da seguinte forma, no segundo capítulo apresenta-se os principais conceitos de Smart Grids, bem como suas características, efeitos e abrangência. Em seguida, aborda-se o processo de gerenciamento de falhas, enfatizando algumas publicações relevantes para este tema. E por fim, apresenta-se um levantamento das principais falhas da rede elétrica brasileira.

No terceiro capítulo são abordados os principais aspectos da inteligência artificial aplicada ao gerenciamento de falhas, conceituando e delimitando o gerenciamento e a classificação das falhas. Neste mesmo capítulo são descritos os parâmetros utilizados para implementação das RNAs.

As falhas na rede elétrica brasileira são descritas no capítulo quatro. A descrição das falhas inclui quais os motivos geradores de sua ocorrência considerando os aspectos da rede elétrica brasileira.

A modelagem e análise do classificador de falhas são descritas no quinto capítulo.

No sexto capítulo são apresentados e discutidos os resultados dos experimentos, a análise de dados, e uma breve discussão o resultado obtido comparado aos trabalhos disponíveis na bibliografia pesquisada. E finalmente, seguem a conclusão, os trabalhos futuros e as referências bibliográficas.

2 SMART GRIDS

2.1 DEFINIÇÃO

As Redes Inteligentes ou *Smart Grids* (SG), em inglês, são realidade na Europa e outros continentes. O termo Smart Grids foi usado pela primeira vez em 2005 em um artigo escrito por S. Massound Amin e Bruce F. Wollenberg, publicado pela revista IEEE P&E, com o título "Toward A Smart Grid". Durante a primeira Conferência Internacional sobre a Integração das Fontes de Energia Distribuídas, realizada em 2004 foi criada a *Plataforma Tecnológica Europeia* (PTE) para as redes de eletricidade do futuro. Em 2006, a PTE apresentou sua visão estratégica para o futuro da rede elétrica europeia, o que incluía a implantação da SG (AMIN; WOLLENBERG, 2005).

A Itália foi pioneira na tentativa de modernização da rede elétrica no início dos anos 2000, um projeto chamado *Telegestone Project*, previu a utilização de cerca de 27 milhões de medidores eletrônicos com capacidade para comunicação via PLC - *Power Line Communications* - que significa transmissão de dados via cabo de energia (ENERGIA, 2012). Atualmente a PTE tem um programa visando a pesquisa e desenvolvimento de Smart Grids até 2035 (IN, 2015).

Apesar das SGs terem como objetivo inicial medições avançadas, novos requisitos e exigências fizeram a indústria de energia expandir seu escopo de atuação. Em virtude das modificações e evoluções necessárias frente à indústria as SG são para a engenharia e áreas afins um dos grandes desafios dessa nova era tecnológica. Composta de elementos digitais e usufruindo da rede elétrica para enviar dados. Conecta todos os usuários, geradores e consumidores com o objetivo de fornecer eletricidade com segurança e estabilidade.

Com a utilização de sensores e controles automatizados a rede será capaz de antecipar, detectar e resolver problemas do sistema. Podendo evitar faltas de energia ou problemas na qualidade do serviço de transmissão. As informações em tempo real possibilitarão o isolamento das áreas afetadas e o redirecionamento do fluxo de energia mantendo o maior número possível de consumidores atendidos(ENERGIA, 2012).

Haja vista todas essas funcionalidades e elementos, as SGs são consideradas uma evolução no sistema de energia e não uma reedição com melhorias. Para isto se tornar real foi preciso unir o sistema de energia com as Tecnologias da Informação e Comunicação (TIC)(SANTIS et al., 2015). Fruto dessa união as SGs devem ser ca-

pazes de atender uma lista de requisitos, são eles:

- Auto-Recuperação;
- Resistir a ataques físicos e cibernéticos;
- Fornecer uma energia de melhor qualidade;
- Permitir vários tipos de geração e armazenagem de energia;
- Maior envolvimento do mercado;
- Permitir uma maior utilização de geração intermitente de energia;

Afim de fornecer um paradigma conceitual de um SG a Figura 1 demonstra os sete campos definidos pelo o Instituto Nacional de Padrões e Tecnologia (INPT).

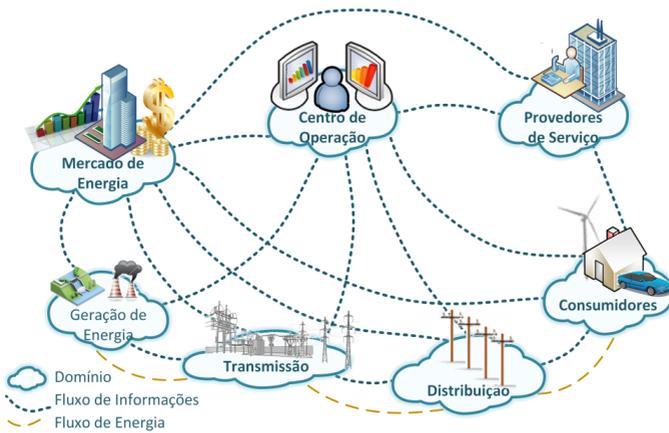


Figura 1 – Modelo Conceitual INPT

Fonte: (SANTIS et al., 2015)

Entretanto para facilitar a compreensão no ponto de vista técnico alguns autores como SANTIS et al. e FANG et al. propõem modelos conceituais mais concisos. SANTIS et al. define a Smart Grid como uma "equação", dada por:

1. Smart Grid = Power Grid + TIC;
2. TIC = Sensores Inteligentes + Rede de Comunicação + Computação;

Onde a soma dos itens 1 e 2 equivale ao *Sistema Nervoso e Cognitivo de uma Rede de Energia*. Em FANG et al. sugere uma divisão em três sistemas principais, são eles: infraestrutura, gestão e Sistemas de proteção inteligentes.

A infraestrutura inteligente é de grande importância pois suporta um fluxo bidirecional de energia elétrica e informação, isso significa dizer que o fornecimento de energia não segue mais o modelo ortodoxo de envio unidirecional. Portanto, na SG, a energia elétrica também pode ser colocada de volta na rede por usuários que possuem geradores próprios, como por exemplo, através do uso de painéis solares.

2.2 SISTEMA DE GERENCIAMENTO DE FALHAS

O subsistema de proteção inteligente juntamente com o os subsistemas citados anteriormente, conseguem prover uma análise avançada da rede. Isto significa que garantem a confiabilidade na entrega tanto de energia quanto de informações. O gerenciamento de falhas é parte deste subsistema e por isso ele fornece serviços de proteção e privacidade (FANG et al., 2012).

As tecnologias envolvidas em cada subsistema podem ser divididas em grupos menores, começando pela exploração e medição inteligente. Os *Smart Meters* são mecanismos importantes para a obtenção de informações. A *infraestrutura automática de medição* (ou IAM) (HART, 2008) é amplamente utilizada junto com o /textitmedidor automático de leitura (ou MAL)(RIEKEN; II, 2011). O MAL consegue recolher automaticamente dados de consumo, e também é responsável por transferir os dados para um banco de dados central com a finalidade de agrupar e solucionar problemas encontrados. Os medidores inteligentes registram o consumo elétrico e enviam essa informação pela rede em intervalos de tempo para que não ocorra um congestionamento na rede, eles se conectam e desconectam apenas quando necessário.

Tendo em vista que o sistema tem uma grande quantidade de dados para monitorar existe a necessidade de encontrar formas de manipular estes dados. Fang et al. (2012) cita a *Unidade de Medição Fasorial*(UMF) e o uso de rede de sensores como formas de gerenciar e manipular os dados.

Os sensores ou rede de sensores possuem inúmeras aplicações na área de monitoramento e medição. Len, Vittal e Manimaran (2007) propôs que as redes de sensores fossem incorporadas na rede de energia para auxiliar e avaliar as condições mecânicas e elétricas das linhas

de transmissão afim de se obter um diagnóstico físico da rede e uma visão do sistema elétrico, tudo em tempo real. Este diagnóstico ajuda no reconhecimento de falhas iminentes ou permanentes tornando mais fácil resolver os problemas.

Gungor, Lu e Hancke (2010) estudou a aplicação de uma Rede de Sensores Sem Fio (RSSF) para sistemas de energia. Nesse estudo, foram experimentados diferentes sistemas de energia elétrica e ao final concluiu que com a ajuda de uma RSSF, um único sistema de contingência de rede pode encontrar e isolar falhas antes que causem efeitos em cascata. Alguns outros trabalhos sobre aplicação de RSSF são Bressan et al. (2010), sua pesquisa foi embasada em uma infraestrutura de roteamento utilizando um protocolo de baixo consumo de energia. Em Gutiérrez et al. (2006), outro trabalho nesta área, apresenta o foco na gestão de energia através de um ciclo fechado da RSSF.

Outras características das redes de sensores associadas aos SGs a serem observadas:

1. Restrição de Recursos (bateria)
2. Qualidade do Serviço (Confiabilidade, latência, e *throughput* da rede)
3. Manutenção (remotamente acessível)
4. Segurança

Outro método, já citado anteriormente, que é utilizado para aferir dados em uma SG é UMF. A UMF mede as ondas elétricas de uma rede de energia para determinar a saúde do sistema. Matematicamente falando um fasor é um número complexo que representa ao mesmo tempo magnitude e fase do seno das ondas encontradas na medição (REE et al., 2010). Com os avanços em UMF os operadores do sistema tem como aliado a capacidade de estimar o estado do sistema elétrico. Tentando tornar o sistema imune a falhas catastróficas vários países como Brasil, China, França, Japão e Coreia do Sul tem instalado UMF em seus sistemas de energia ou já estão desenvolvendo protótipos (ZHANG; LI; BHATT, 2010).

Redes de sensores e medição fasorial são métodos bastante empregados em sistemas de energia, porém estes algoritmos necessitam de uma grande quantidade de processamento e uma quantia grande de tempo para dar previsões precisas. Uma solução que tem sido bem aceita para previsão e gerenciamento de falhas é a utilização de Redes Neurais Artificiais (RNAs). As RNAs são capazes de aprender padrões

e generalizar o conteúdo aprendido dentro de um determinado segmento a partir de um conjunto de dados de entrada(ATA, 2015).

2.3 LEVANTAMENTO DE FALHAS NA REDE ELÉTRICA BRASILEIRA

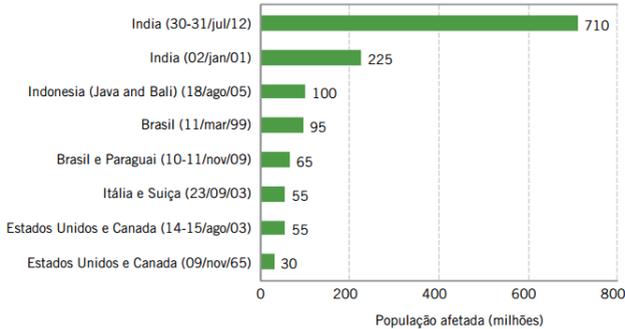
No Brasil, o sistema de transmissão de energia elétrica ainda é o tradicional, portanto as tecnologias de redes de comunicação ainda são as mesmas desde sua primeira instalação. Elas vem funcionando bem, entretanto não serão capazes de enfrentar as mudanças advindas da implantação de redes inteligentes. Uma premissa básica para a implementação de Smart Grids é que toda a rede elétrica até o consumidor final seja completamente automatizada, situação oposta ao atual cenário brasileiro(ENERGIA, 2012).

Em contrapartida, mesmo que este cenário não seja o mais propício para a implantação, ele vem atualizando os indicadores de qualidade da rede. A melhora na qualidade é uma das vantagens na implantação das SM, mas para isso é necessário entender quais são as falhas e de que maneiras elas são mensuradas.

A maioria das interrupções ocorrem nas redes de distribuição, algo esperado devido a grande capilaridade da rede e a alta exposição ao surgimento de ocorrências. O Brasil conta com cerca de 2 milhões de quilômetros de linhas de distribuição e 107 mil quilômetros de linhas de transmissão. Existem diversas formas de medir a gravidade de um blecaute: magnitude da demanda interrompida, o tempo de duração, o impacto econômico gerado, o número de consumidores afetados. Independente do critério utilizado, o Brasil se destaca por ter sofrido alguns dos maiores blecautes da história. A Figura 2 apresenta alguns dos maiores blecautes já registrados no mundo em termos de pessoas afetadas. O Brasil tem 2 entre os 8 maiores blecautes de todo o mundo(LOPES; FERNANDES; CHRISTINA, 2015).

O sistema elétrico brasileiro é suscetível a blecautes de larga escala devido ao suprimento de energia depender de grandes usinas hidrelétricas muito distantes dos centros de carga. Isso exige que as linhas de transmissão fiquem expostas às intempéries por seu grande comprimento. Além disso, devido ao aumento da população e ao crescimento do número de equipamentos em uso nas residências a demanda por energia tem crescido cada vez mais nos últimos anos(Instituto Acende Brasil, 2014).

A demanda crescente de energia somada a infraestrutura frágil



Fonte: Clean Technica, Union of Concerned Scientists, Ovoenergy, Associated Press.

Figura 2 – Maiores Blecautes no Mundo

Fonte: (SAMADI et al., 2010)

tornam-se mais um fator para a ocorrência de falhas na rede. Alguns dos principais problemas do sistema atual são:

- Geração de energia de forma não-renovável e alterações climáticas: No Brasil, como mostra a Figura 3, o uso das termelétricas aumentou, e isso ocorreu devido à falta de chuvas. As termelétricas agiram para substituir parte da geração hidrelétrica, com isso, ajudaram a poupar água para que a situação brasileira não se agravasse. Mas como eles funcionam por meio da queima de combustíveis a energia que produzem costuma ser muito mais cara (SAMADI et al., 2010);
- Infraestrutura fragilizada e antiga;
- Geração de energia centralizada;
- Aumento da população e crescente demanda de energia;
- Deterioração da confiança: O sistema elétrico atual é solicitado a ser 99,97% confiável, mas ainda permite a falta de energia e interrupções. A falta de confiabilidade no sistema elétrico atual advém do uso de fontes de energia centralizada e longe dos grandes centros;
- Fluxo unidirecional de comunicação e de energia: não há interação entre os serviços e os consumidores. O sistema utilizado não permite que o consumidor perceba os reflexos decorrentes da

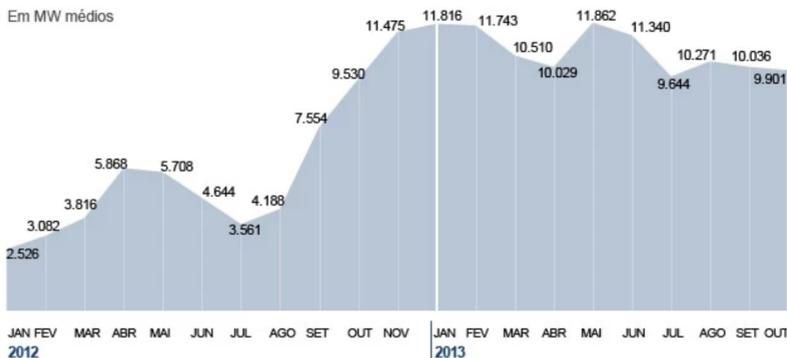


Figura 3 – Aumento da Utilização de Termelétricas no Brasil
 Fonte: (SAMADI et al., 2010)

forma de usar a eletricidades e tome decisões de acordo com as informações recebidas.

Estes problemas são a origem das falhas que o sistema inteligente tem ambição de tratar. Para dividir em categorias as falhas existentes no Brasil, foi utilizado o trabalho (TRONCHONI, 2008) que tem como objetivo a identificação das causas dos desligamentos não programados. E o trabalho (OPRISAN et al., 1991) onde foi desenvolvido um sistema para armazenamento de dados sobre interrupção de energia para cálculo do desempenho da rede. No trabalho(OPRISAN et al., 1991) para cada evento ocorrido os dados são armazenados de forma a vincular o desligamento a uma das sete grandes categorias de equipamentos:

1. Linha de Distribuição;
2. Cabo de Distribuição;
3. Transformador de Distribuição;
4. Transformador de Potência;
5. Chaves;
6. Reguladores;
7. Capacitores;

Sabendo dos problemas que a rede brasileira enfrenta vemos que os blecautes tem origem em uma destas 7 categorias, isto será útil para a modelagem do classificador de falhas presente, componente do gerenciador.

3 INTELIGÊNCIA ARTIFICIAL (IA) E GERENCIAMENTO DE FALHAS

3.1 PRINCIPAIS APLICAÇÕES NA ATUALIDADE

Raciocinar, tomar decisões e resolver problemas de forma lógica são algumas das competências envolvidas nas pesquisas das técnicas de IA. Podem ser empregadas nas soluções de diversos tipos de problemas, tais como: confecção de motores de jogos, reconhecimento de padrões, classificação de dados e segurança, a IA pode resolver problemas de grande complexidade de forma rápida e eficiente. Devido estas características, uma das técnicas que se destaca na solução de problemas relacionados com o gerenciamento da falhas e sistemas de energia são o uso de redes neurais artificiais (RNAs). Nos próximos parágrafos são apresentados diversos trabalhos desenvolvidos com o auxílio destas técnicas voltados os setor de energia elétrica. Zhang, Li e Bhatt (2010) mostra uma solução de gerenciamento baseada na previsão da curva de carga a curto prazo na rede elétrica, empregando uma RNA treinada com o algoritmo *Backpropagation*. Segundo o autor, este experimento obteve sucesso pois revelou os defeitos da rede elétrica durante a análise do gradiente da curva de carga que constatou existir alguns mínimos locais e distorções que antes não eram detectadas pelo método de medição fasorial. Fazendo um paralelo com o método matemático de medição fasorial, um trabalho de destaque é Bose (2010) que realizou um estudo sobre a implantação de um sistema de monitoramento ambiental inteligente. Este trabalho aborda qualidade da rede de transmissão e distribuição de energia juntamente com a infraestrutura de informação para suportar a medição fasorial por meio da implantação de uma rede multilayer perceptron.

Outro trabalho a destacar que também utiliza técnicas de IA é (HERNANDEZ et al., 2013), o qual implementa uma rede neural multilayer perceptron (MLP), entretanto, para resolver outro problema: o estudo da gestão inteligente de redes de energia renovável utilizando um conjunto de multiagentes encaixados com a rede MLP para a previsão de demanda colaborativa de energia, tanto para usuários domésticos quanto usuários finais.

As RNAs tem sido amplamente utilizadas em diversas aplicações da área de energia, entre estas aplicações destacam-se: reconhecimento de padrões, otimização e aproximação de resultados, simulação, previsão entre muitas outras áreas. Um setor que vem utilizando com êxito

as RNAs é a captação energética a partir de aerogeradores. Bangalore e Tjernberg (2013) utilizou um algoritmo evolutivo para monitorar em tempo real uma turbina eólica. A RNA utilizada foi construída de modo a gerar seu conjunto de dados de treino, processo automatizado pelo algoritmo. A rede sincronizou as mudanças da condição de funcionamento da turbina e fez previsão de falhas precisas e confiáveis.

Yang, Li e Wang (2008) mostrou uma RNA com três camadas para diagnosticar falhas na caixa de velocidades do aerogerador. As características desse processo foram pré-modeladas na rede. A rede possui nove nós de entrada, cada entrada representando um sensor de vibração instalado em diferentes partes. A RNA proposta foi construída como uma rede que tem 9 neurônios na camada de entrada, 10 na camada intermediária e 4 na camada de saída (9-10-4), e foi treinada utilizando o algoritmo *back propagation* com função sigmóide obtendo sucesso no diagnóstico proposto.

Guolian et al. (2010) desenvolveu um algoritmo de rede para monitorar falhas no sistema de controle de turbinas eólicas utilizando uma RNA simples e um algoritmo genético. Os algoritmos foram utilizados para explorar e melhorar a velocidade de convergência da rede, o algoritmo genético foi empregado com o objetivo de evitar que a RNA ficasse presa no seu mínimo local. A rede proposta contou com um esquema de camadas (6-5-3). Após ser testado para seis tipos de falhas foi validado com grande sucesso.

Em (YOU; ZHANG, 2012) foi aplicado um recurso de auto-organização, a Rede Neural auto-organizável (*Self Organized Maps - SOM*) para realisar o diagnóstico de falhas no conversor da turbina eólica. A rede SOM é uma rede de duas camadas que aceita padrões de N-dimensões como entrada e mapeando-os para um conjunto de neurônios de saída, o qual representa o espaço dos dados a serem agrupados. Os pesquisadores utilizaram ferramentas do MatLab para treinar e simular a rede. Os resultados obtidos mostraram que as redes do tipo SOM permitem efetivar um diagnóstico confiável para o sistema em questão.

Schlechtingen e Santos (2011) em seu trabalho utilizou três modelos implementados usando dados do SCADA online, estes modelos foram comparados utilizando um comportamento normal auto regressivo. Os pesquisadores investigaram a capacidade de identificar a falha incipiente antes da falha real. A comparação dos resultados revelam que os três modelos apresentam boa capacidade para detectar as falhas incipientes. Entretanto, os três modelos diferem no esforço necessário para o desenvolvimento e no tempo de operação, após a primeira indicação de falhas.

Nas próximas seções são apresentados os conceitos envolvidos no estudo e aplicação de RNAs, modelagem e aprendizado necessários para o desenvolvimento do presente trabalho.

3.2 REDES NEURAIS ARTIFICIAIS (RNAs)

Uma RNA é um sistema computacional constituído por unidades de processamento individuais interconectados entre si. Cada unidade possui pesos que podem ser modificados de acordo com os parâmetros que avaliam a proximidade entre a resposta desejada e a resposta obtida durante o período de treinamento (RAZA; KHOSRAVI, 2015).

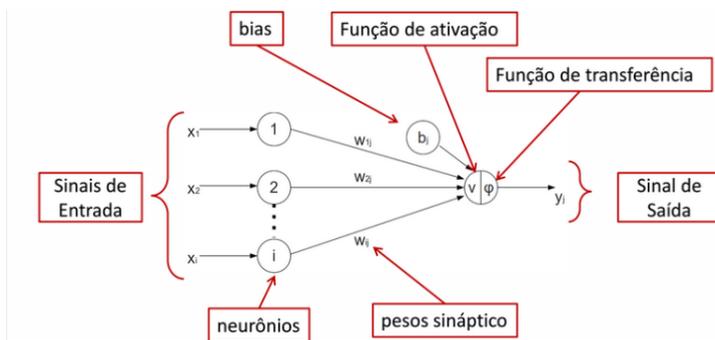


Figura 4 – Neurônio Artificial
Fonte: (RAZA; KHOSRAVI, 2015)

Da mesma forma que o neurônio biológico, o neurônio artificial possui entradas semelhantes aos dendritos que captam as informações provenientes do meio externo e saída semelhante ao axônio. No fim da década de 1950, um projeto chamado Perceptron foi desenvolvido por Frank Rosenblatt na Universidade de Cornell, a partir dos estudos de McCulloch. Utilizando a proposta do algoritmo de treinamento da rede baseado no estudo do biólogo Donald Hebb de 1949, que usava o ajuste gradual dos pesos de um discriminante linear. Este projeto utilizava neurônios com pesos ajustáveis para a classificação de padrões linearmente separáveis. A rede era treinada para fornecer saídas de acordo com os dados do conjunto de treinamento, para padrões vetoriais (QUEIROZ, 2010). Na Figura 4 é possível identificar três elementos básicos do modelo neural (HAYKIN, 2001):

1. Um **conjunto de sinapses**, cada uma caracterizada por um

peso. Ao contrário de uma sinapse no cérebro, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos ou positivos dependendo do tipo de função de ativação.

2. Um **somador** para somar os sinais de entrada, ponderadas pelas respectivas sinapses do neurônio.
3. Uma **função de ativação** para restringir a amplitude da saída de um neurônio.

O multilayer perceptron (MLP) é uma sofisticação do modelo original de Perceptron. Com ampliação do número de camadas interconectadas, ampliou também o espectro de problemas de classificação que podem ser resolvidos pela rede. Na camada de neurônios de entrada, os vetores (dados) são recebidos e armazenados, dependendo da arquitetura da rede. Na camada mais interna entre os neurônios de entrada e saída pode haver uma camada intermediária. A camada de saída tem a função de armazenar as respostas obtidas pela rede (DUTRA; SPERANDIO; COELHO, 2004). O número de neurônios nessa camada corresponde ao tamanho do vetor de saída na Figura 5.

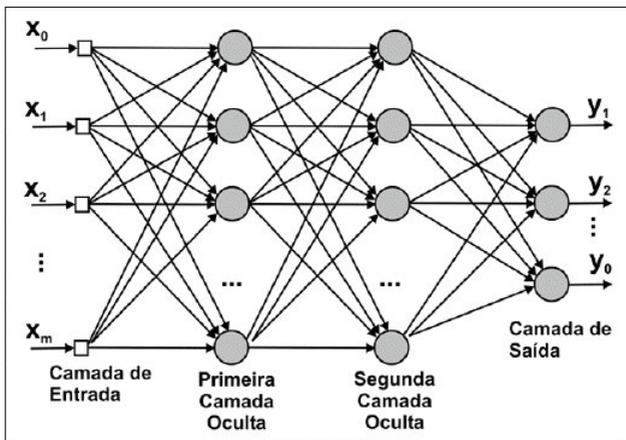


Figura 5 – Rede MLP

Fonte: (DUTRA; SPERANDIO; COELHO, 2004)

3.3 PROCESSOS DE APRENDIZAGEM

Ainda que a aprendizagem tenha diversas atividades ligadas a ela, este processo depende do ponto de análise, por este motivo tem-se dificuldade de obter um consenso sobre sua definição. Porém existe a certeza que na aprendizagem reside uma das mais importantes características de uma RNA, a habilidade de efetuar generalizações a partir de informações contidas nos padrões que existem em determinado ambiente (BRAGA, 2007).

Basicamente, os algoritmos de aprendizagem diferem entre si pela forma como é formulado o ajuste de peso sináptico de um neurônio. Outro fator a ser considerado é a maneira pela qual uma rede neural, se relaciona com o seu ambiente. Existem cinco regras de aprendizagem, *aprendizagem por correção de erro*, *aprendizagem baseada em memória*, a mais clássica *aprendizagem Hebbiana*, *aprendizagem de Boltzmann* e a *aprendizagem competitiva*, básicas para o projeto de redes neurais. Veremos o aprendizado competitivo, as demais formas de aprendizagem podem ser estudadas no livro (HAYKIN, 2001)

3.3.1 Aprendizado Competitivo

No aprendizado competitivo os neurônios de saída de uma RNA competem entre si para tornar-se ativos. Enquanto que na RNA baseada no *aprendizado Hebbiano* vários neurônios de saída podem estar simultaneamente ativos, no aprendizado competitivo apenas um único neurônio de saída está ativo em um determinado tempo. Isso torna o aprendizado competitivo útil para descobrir traços ou características estatisticamente salientes que podem ser usados para classificar um conjunto de padrões de entrada (TSODYKS; GILBERT, 2004). Há três elementos básicos a uma regra do aprendizado competitivo (MASSON; WANG, 1990):

1. Um conjunto de neurônios, onde os elementos são todos os mesmos, exceto por alguns pesos sinápticos distribuídos aleatoriamente e que portanto respondem diferentemente a um dado conjunto de padrões de entrada.
2. Um limite imposto na “força” de cada neurônio.
3. Os neurônios individuais da rede aprendem a conjuntos de padrões similares; assim tornam-se detentores de características para

diferentes classes de padrões de entrada.

Na forma mais simples do aprendizado competitivo, a RNA tem uma única camada de neurônios de saída. A rede pode incluir conexões de retroalimentação entre os neurônios, como indicado na Figura 6, realizando inibição lateral. As conexões sinápticas com alimentação a frente são todas excitatórias. Para um neurônio k ser o vencedor, seu campo local induzido V_k para um padrão de entrada \mathbf{x} deve ser o maior entre todos os neurônios da rede (TSODYKS; GILBERT, 2004), para isso y_k tem que ser igual à:

$$\begin{cases} 1, & \text{se } V_k > V_j \text{ para todo } j, j \neq k \\ 0, & \text{caso contrario} \end{cases} \quad (3.1)$$

Onde V_k representa a ação combinada de todas as entradas *forward* e *feedback* ao neurônio k .

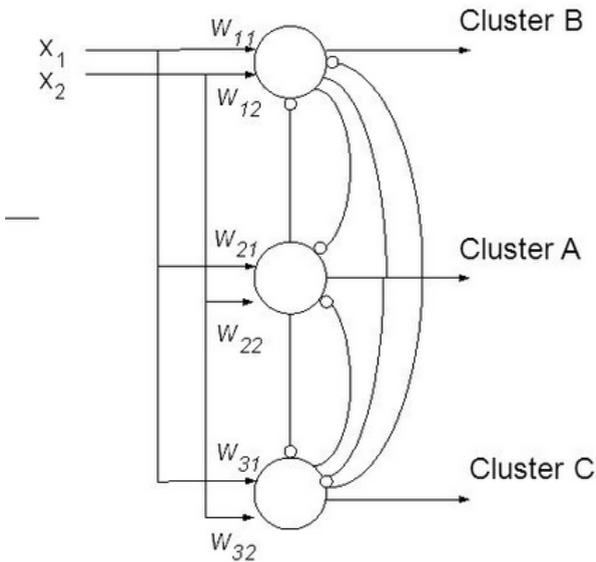


Figura 6 – Aprendizado competitivo para a separação de entradas.
Fonte: (TSODYKS; GILBERT, 2004)

Seja $W_{k,j}$ o peso sináptico que conecta o nó de entrada j ao neurônio k . Suponha que a cada neurônio aloca uma quantidade fixa

de peso sináptico positivo, distribuído entre os nós de entrada.

$$\sum_j W_{kj} = 1, \text{ para todo } k \quad (3.2)$$

Um neurônio aprende deslocando pesos sinápticos dos nós de entrada inativos para ativos. Se um neurônio ganha a competição, cada nó de entrada deste neurônio cede alguma proporção de seu peso sináptico e o peso cedido é então distribuído igualmente entre os nós de entrada ativos, onde ΔW_{kj} é igual à:

$$\left\{ \begin{array}{l} \eta(X_j - W_{kj}), \text{ se o neurônio } k \text{ vence a competição} \\ 0, \text{ se o neurônio } k \text{ perde a competição} \end{array} \right\} \quad (3.3)$$

Esta regra move o vetor de peso sináptico W_k do neurônio vencedor k em direção ao padrão de entrada \mathbf{x} (HAYKIN, 2001).

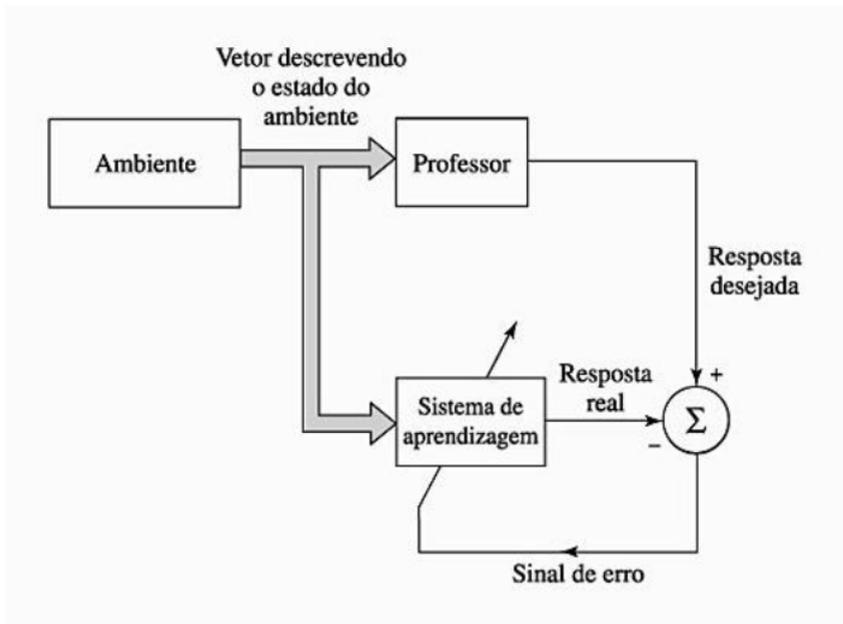


Figura 7 – Diagrama em blocos da aprendizagem com professor
Fonte: (HAYKIN, 2001)

Em termos conceituais, considera-se o professor como tendo conhecimento sobre o ambiente. Este está apto a prover a resposta desejada à RNA para determinado vetor de treinamento. Os parâmetros da rede são ajustados de acordo com o vetor de treinamento e o sinal de erro. É definido como a diferença entre a resposta desejada e a resposta real da rede, tendo seu ajuste feito de forma iterativa, ou seja, passo a passo até que finalmente faz a RNA emular o professor.

- Off-line: uma vez que a resposta desejada é obtida, o projeto é congelado. A rede opera no modo estático.
- On-line : o aprendizado é executado em tempo real. A rede neural é dinâmica.

3.3.2 Classificação com Redes Neurais

As RNAs podem ser empregadas nos sistemas de **reconhecimento de padrões**, onde um padrão ou sinal recebido é atribuído a uma classe dentre um número predeterminado de classes. Uma RNA pode ser utilizada passando primeiro por uma sessão de treinamento, durante a qual se apresenta repetidamente à rede um conjunto de padrões de entrada junto com a categoria à qual cada padrão particular pertence. Sistemas de reconhecimento de padrões possuem etapas distintas de extração de características e posteriormente de classificação. O reconhecimento de padrões realizado por uma RNA, normalmente possui natureza estatística, com padrões sendo representados por pontos em um espaço de decisão multidimensional. Este espaço é dividido em regiões, cada uma delas associada a uma classe diferente. As fronteiras de decisão são determinadas pelo processo de treinamento.

De forma genérica, sistemas de reconhecimento de padrões que utilizam RNA podem assumir uma das duas formas a seguir:

1. A máquina é dividida em duas partes, uma rede não-supervisionada para extração de características e uma rede supervisionada para a classificação, como mostra a Figura 8.

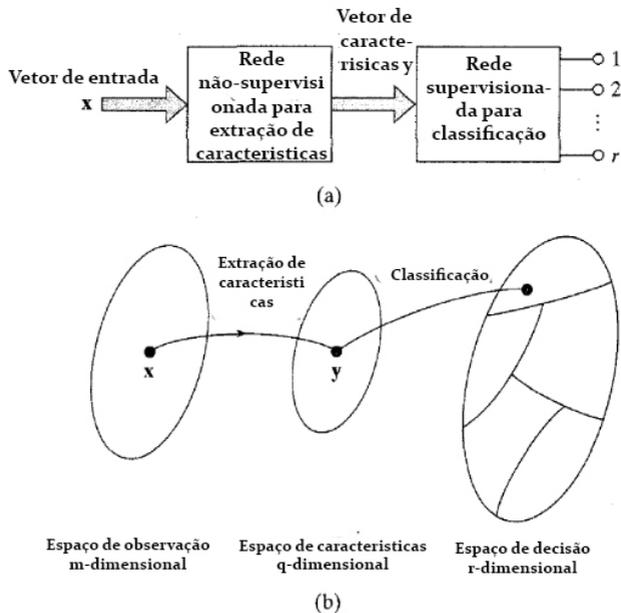


Figura 8 – Reconhecimento de padrões.
Fonte: (HAYKIN, 2001)

2. A máquina é projetada como uma única rede de múltiplas camadas alimentada adiante, utilizando um algoritmo de aprendizagem supervisionada. Aqui a tarefa de extração de características é realizada pelas unidades computacionais da camada(s) oculta da rede.

3.3.3 Perceptrons de Múltiplas Camadas e seu Treinamento

Multylayer Perceptron (MLP) são RNAs utilizadas para a solução de problemas de alta complexidade onde as classes são não linearmente separáveis, já que os perceptrons de múltiplas camadas têm a capacidade de aproximar qualquer função não linear, mesmo que descontínua, enquanto os de camada única tem alimitação de solucionar apenas problemas em que as classes não são linearmente separáveis.

Uma forma de avaliar seu desempenho é o *Algoritmo de Retropropagação do Erro* : O MLP é tipicamente treinado de forma supervisionada, por meio do algoritmo de retropropagação do erro, também

conhecido como *Backpropagation*. Este algoritmo consiste basicamente em uma primeira etapa em que um vetor com os padrões de entrada é propagado para frente, nesta etapa os pesos sinápticos são mantidos fixos. Na segunda parte o sinal de erro gerado na saída da rede é então retropropagado de forma a ajustar os pesos sinápticos. O processo se repete até que a resposta real esta suficientemente próxima da resposta desejada de acordo com o objetivo definido pelo projeto Guerra, Prudêncio e Ludermir (2007)

Para sustentar a escolha da MLP o argumento de (SILVA L. R. B.; BERTACHI, 2013) diz que essa configuração de rede é pode ser considerada versátil quanto a aplicabilidade. Sendo característica a elevada possibilidade de adaptação a problemas de: aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas.

Esta última aplicação, otimização de sistemas, é atualmente realizada em sua maioria empregando algoritmos genéticos. Por isso, na próxima seção é feita uma breve explanação sobre algoritmos genéticos utilizados na otimização de sistemas.

3.4 ALGORITMOS GENÉTICOS EMPREGADOS NA OTIMIZAÇÃO DA ARQUITETURAS DE RNAS

Os algoritmos genéticos (AG) consistem em técnicas inspiradas na biologia evolutiva, são capazes de encontrar soluções aproximadas em problemas de otimização. O algoritmo especializa a população para adaptar-se a um determinado contexto. Por ser um algoritmo bastante simples porém, eficiente como demonstra o trabalho de ALMEIDA et al., o AG analisa a melhor estratégia de venda, primeiro com uma RNA estruturada de forma empírica e faz a compara com outra RNA estruturada com AG. KRAUSE utilizou AG com o objetivo central de otimizar a arquitetura de RNAs resolvendo problemas biológicos e biotecnológicos, como relata o trabalho. Os AG podem auxiliar na determinação e otimização da arquitetura da RNA a ser empregada em um projeto. No presente trabalho, o AG proposto por Santos et al. (2016) será utilizado para estimar a melhor configuração de uma RNA. Através do emprego deste AG é possível estimar o melhor número de camadas e neurônios para que uma RNA determinada seja capaz de classificar um conjunto de falhas na rede elétrica.

4 FALHAS PRESENTES NO SISTEMA ELÉTRICO

O sistema elétrico brasileiro é bastante complexo e possui, assim como em outros países, uma gama de fenômenos que podem ser traduzidos como distorções, tanto de corrente quanto de tensão. Estes fenômenos estão relacionados aos equipamentos que conduzem a rede, tais como acopladores, capacitores, cabos e transformadores. Nos pontos de acoplamento ou dentro das unidades consumidoras é que estão as maiores ocorrências de distúrbios.

Estes distúrbios podem ser definidos como "qualquer desvio que possa ocorrer na magnitude, forma de onda ou frequência da tensão e/ou corrente elétrica, que resulte em falha ou operação indevida de equipamentos elétricos". Entretanto a classificação dos indicadores para controlar a qualidade da energia tem uma complexidade elevada e apresenta peculiaridades técnicas que tornam complicada esta tarefa (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2016). Todavia destacam-se alguns pontos, tais como:

- Caráter aleatório nas ocorrências de distúrbios de qualidade na energia;
- Inevitabilidade técnica de ocorrências destes distúrbios;
- Variado nível de sensibilidade dos consumidores;
- Dificuldade de executar controle prévio da qualidade; e,
- Extensa área de vulnerabilidade do sistema elétrico, representado por milhares de quilômetros de linhas de transmissão, sub transmissão e distribuição aéreas.

Os distúrbios causadores de falhas no sistema elétrico podem ser categorizados em alguns grupos principais, comuns as três faixas de tensão: baixa, média e alta.

1. Transitórios: são fenômenos oriundos de alterações temporárias nas condições de funcionamento de um sistema. Sua duração é muito pequena, porem pode afetar equipamentos que solicitam alto valor de tensão e corrente. Mais comuns na rede de Baixa e média tensão. Podem ainda ser divididos em: Impulsivos, causados por descargas atmosféricas, oscilatórios, causados por chaveamento (ZAMBONI, 2013).

2. Variação de tensão de curta duração: são marcadas por alterações instantâneas, momentâneas ou temporárias. Tem sua causa em energização de grandes cargas que requerem altas correntes de partida ou por falha intermitente nas conexões dos cabos do sistema. Por suas características de alta corrente e tensão, são mais comuns nas altas e médias tensões. Suas consequências incluem afundamento de tensão, elevação momentânea de tensão ou ainda interrupção completa de um sistema (ZAMBONI, 2013).
3. Variações de tensão de longa duração: tem características semelhantes aos de curta duração, porém, com período de ocorrência superior à três minutos. Causados por grandes blocos de carga e percas de fase podem ser encontrados nas três faixas de tensão (ZAMBONI, 2013).
4. Desequilíbrios: marcado por um desvio máximo da média das correntes ou tensões trifásicas. As causas são geralmente encontradas na distribuição, que possuem cargas monofásicas distribuídas inadequadamente, ocasionando tensões negativas. A situação pode ser agravada se os consumidores possuírem circuitos internos mau distribuídos. Este fenômeno é comumente encontrado nas médias e baixas tensões (ZAMBONI, 2013).
5. Distorção da Forma de onda - Harmônicos, cortes de tensão e ruídos: A análise de onda é normalmente feita em sistemas de média tensão e com condas puramente senoidais (RIEKEN; II, 2011).
 - Harmônicos: tensões ou correntes senoidais de frequências múltiplas inteiras da frequência fundamental (60 Hz). Estes harmônicos distorcem as formas de onda da tensão e corrente e são oriundos de equipamentos e cargas com características não lineares.
 - Inter-harmônicos: componentes de frequência, em tensão ou corrente, que não são múltiplos inteiros da frequência fundamental. Podem aparecer como frequências discretas ou como uma larga faixa espectral. São encontrados nas diferentes classes de tensão. Os principais fatores de causa são conversores estáticos de potência, clico-conversores, motores de indução e equipamentos a arco.
 - Notching: distúrbio de tensão causado pela operação normal de equipamentos de eletrônica de potência quando a corrente é comutada de uma fase para outra. Este fenômeno

pode ser detectado pelo conteúdo harmônico da tensão. As componentes de frequência associadas são de alto valor.

- Ruído: definido como um sinal elétrico indesejado, contendo uma larga faixa espectral com frequências menores que 200Khz, as quais são superpostas às tensões ou correntes de fase, ou encontradas em condutores de neutro (ENERGIA, 2012).

6. Variações de frequência: são desvios no valor da frequência fundamental do sistema. A frequência está intimamente ligada a velocidade de rotação dos geradores que suprem o sistema. Variações que ultrapassam os limites para operação normal em regime permanente podem ser causadas por falhas em sistemas de transmissão, saída de um grande bloco de carga ou pela saída de operação de uma grande fonte de geração (TRONCHONI, 2008).

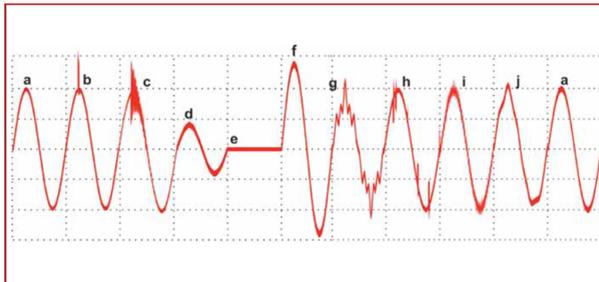


Figura 9 – Espectro senoidal variando de acordo com as perturbações

- a - tensão senoidal
- b - transitório impulsivo
- c - transitório oscilatório de tensão
- d - afundamento de tensão
- e - interrupção
- f - salto de tensão
- g - harmônico
- h - corte de tensão
- i ruídos

- j - inter-harmônicos

No falhas por curto-circuito, conhecidas como falhas assimétricas. São encontradas em maior número na rede elétrica, podem ocorrer com um dois ou três condutores. O que significa que são encontradas nas redes mono, bi e trifásicas. Quando um disjuntor ou chave não fecha uma, duas ou as três fases, diz-se que ocorreu uma falha em série. São também classificadas em Shunt por tratarem da queda de de fase atrelada á terra e podem trazer problemas ainda maiores que as falhas apenas com curto-circuito entre fases (LEMOS et al., 2008). Elas são classificadas em:

- Fase-Terra (monofásica): esse tipo de falha ocorre em cerca de 70% dos casos de curto-circuito. A figura 10 mostra um circuito equivalente de um sistema elétrica que está submetido a uma falha fase-terra (LU et al., 2014).

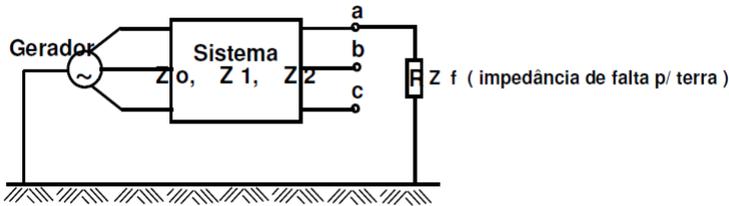


Figura 10 – Representação do circuito fase-terra

- Fase-Fase (bifásica): Segunda maior ocorrência em 15% dos casos de curto-circuito.

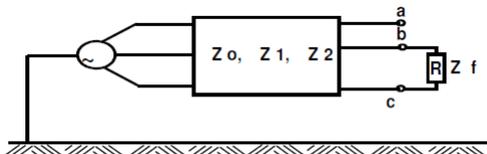


Figura 11 – Representação do circuito fase-fase

Os 15% restante são divididos entre os próximos três tipos de falhas

- Fase-Fase-Terra (bifásico com contato para terra)

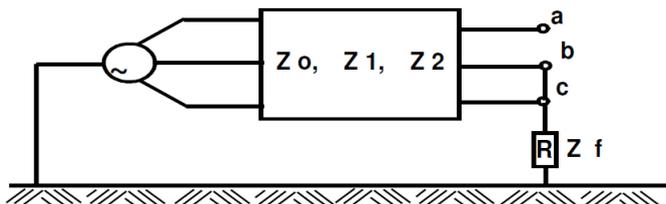


Figura 12 – Representação do circuito fase-fase-terra

- Fase-Fase-Fase (trifásico): Representa-se o circuito equivalente que contem a falha F-F-F como na figura 13:

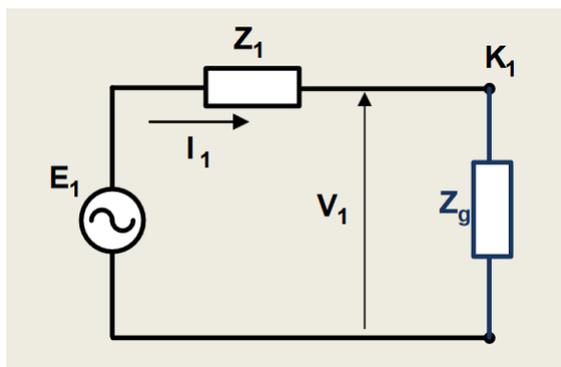


Figura 13 – Representação do circuito fase-fase-terra

- Fase-Fase-Fase-Terra (trifásico com contato para terra)

No Brasil, as linhas com tensão superior a 230kV constituem a chamada rede básica de transmissão. A grande maioria das linhas de transmissão que atuam entre 69 Kv e 138 kV que são de responsabilidade das empresas distribuidoras de energia. Sabendo que as falhas assimétricas estão presentes nas três fases da rede elétrica, infere-se a melhor representação de falhas (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2016). Portanto, com o intuito da representação mais próxima da realidade serão utilizadas para desenvolver no próximo capítulo uma RNA de classificação de falhas.

5 MODELAGEM, SIMULAÇÃO E RESULTADOS

5.1 MODELAGEM

Um módulo fundamental da Smart Grid é o gerenciador de falhas, pois ele é o responsável por localizar os pontos de falhas na rede, classificar as falhas encontradas e proporcionar um mecanismo para tomada de decisão a respeito da situação de falha. Portanto, com ele é possível melhorar a qualidade da rede elétrica como relata OLESKOVICZ; COURY; AGGARWAL em seu trabalho. A detecção, classificação e localização das falhas na linhas de transmissão demonstrou que o desempenho global das arquiteturas de redes neurais implementadas alcançou um índice altamente satisfatório no que diz respeito a precisão e velocidade das respostas.

Sabendo da grande importância que o gerenciamento tem, a ideia inicial deste trabalho foi implementar os três módulos compostos por três redes neurais distintas e empregadas nas tarefas de localização, classificação da falha e tomada de decisão. Mas os planos foram frustrados após inúmeros contatos com a empresa de energia Celesc e nenhum retorno positivo acerca dos dados que seriam necessário para modelagem, treinamento e validação das redes neurais. Então com tempo reduzido e próximo do prazo a solução foi desenvolver uma RNA focada na classificação de falhas.

Dessa forma a escolha do sistema a ser modelado segue os padrões de classificação de falhas da rede elétrica de alta tensão, utilizando dados do sistema elétrico com base na referência (CRUZ, 2005), resultado da utilização do Matlab, com a biblioteca *SimPower System*. Também buscando enriquecer a proposta de elaboração do classificador, foi utilizado o Algoritmo Genético para encontrar a melhor configuração de camadas e neurônios numa segunda RNA de classificação. E assim poder demonstrar qual a melhor escolha de arquitetura da rede e encontrar uma solução confiável capaz de compor um gerenciador de falhas.

Como MÅSSON; WANG fala em seu trabalho, o assunto que se deseja tratar é fator preponderante para a configuração da arquitetura de uma RNA. Esta configuração é composta por número de camadas internas e número de neurônios dessas camadas. A entrada e a saída da rede são consequência do tipo de problema que se deseja resolver. Seguindo o exemplo de MÅSSON; WANG que implementou uma RNA de classificação, as redes neurais desenvolvidas aqui são MLPs com algoritmo

Backpropagation, e aprendizado supervisionado.

De acordo com os trabalhos (OLESKOVICZ; COURY; AGGARWAL, 2003) e também (SILVA, 2014) o aprendizado supervisionado é uma boa alternativa para resolver problemas onde se conhece as saídas desejadas. Pois o esse tipo de aprendizado precisa ter conhecimento prévio das características a que cada padrão pertence, buscando minimizar o erro entre a saída obtida pela rede e a saída desejada.

Considerando o conjunto de dados de treinamento que é composto pelas características das falhas apresentadas no capítulo anterior, existe uma tabelas de "pares ordenados" compostos por uma entrada e uma saída desejada. De acordo com SANTIS et al. o projeto da RNA pode prosseguir assim :

1. A primeira fase de aprendizagem conta com a seleção de um conjunto de exemplos, que serão utilizados para treinar a rede.
2. A segunda fase, outra parte do conjunto de dados é utilizada para verificar o desempenho da rede de classificação, com o propósito de validar a capacidade de generalização da RNA e também evitar o "overtraining".
3. Por fim a terceira fase, consiste no teste, a rede é submetida a dados diferentes dos utilizados na primeira e segunda fase. O desempenho é estimado comparando-se o reconhecimento do dado fornecido pela rede com a real característica que o dado apresenta. Esse processo é repetido até que obtenha uma desempenho aceitável da rede.

Sabendo do processo de treinamento utilizado e qual problema quer se resolver, agora a melhor configuração pode ser definida para as arquitetura das rede que farão a classificação de falhas.

Seguindo os critérios para configuração da rede utilizados por MÅSSON; WANG e também (MUNÁRRIZ, 1994). Emprega-se a técnica empírica de definição das camadas, porém de grande aceitação pela literatura (HAYKIN, 2000): para definir o número de camadas de entrada e saída da rede, pode ser levando em consideração o número de entradas. Portanto após diversos testes, começando com duas camadas internas e 12 neurônios em cada uma delas, foi encontrada a melhor configuração de acordo com o menor erro. 24 neurônios na primeira cada oculta, dobro da entrada e 12 na segunda camada oculta, exatamente o mesmo número de entradas é encontrado o melhor desempenho para está rede. Na segunda RNA analisada a configuração da rede é encontrada por meio de um algoritmo genético de (SANTOS et al., 2016)

que a partir de padrões chave consegue encontrar a melhor configuração da RNA para o problema que se deseja resolver, classificar falhas.

O sistema elétrico que fornece as falhas para análise é composto de dois circuitos simples de 765 kV, com a geração sendo feita em 18kV, 7370 MVA, relação X/R=25, sem acoplamento mútuo entre circuitos, compensados por bancos de capacitores série e por reatores em derivação. A modelagem do sistema de transmissão reproduzido e analisado é feita através de sua representação por parâmetros distribuídos em componentes de fase, com parâmetros unitários sendo utilizados em seus referenciais de sequência positiva, negativa e zero. Desta forma uma representação perfeitamente balanceada é assumida. A figura 14 mostra o sistema de transmissão utilizado por Cruz (2005) nas simulações para diferentes tipos de falhas aplicadas em diversas localizações ao longo dos três trechos.

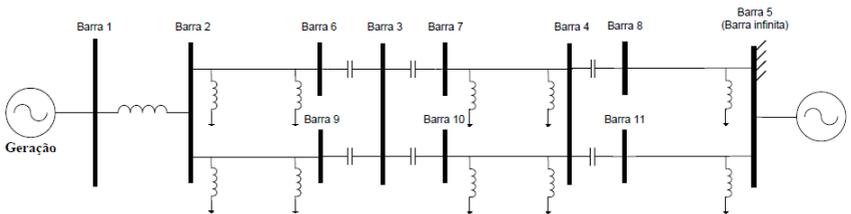


Figura 14 – Modelo do sistema de transmissão

A análise matemática do sistema utilizado pode ser encontrada em (CRUZ, 2005).

5.1.1 Dados do vetor de entrada

Para entrada da Rede Neural Artificial foi necessário condicionar os dados oscilográficos obtidos através dos canais transdutores, que carregam os sinais de alta frequência provenientes dos transitórios que surgem durante a ocorrência da falha e do próprio processo de transdução analógica. Por meio da análise do espectro de frequência obtemos o erro, também conhecido com Aliasing. Caracterizado pela sobreposição de espectros nos qual uma componente de alta frequência superposta ao sinal desejado se manifesta como sendo uma componente de baixa frequência (Tensão, Corrente, Potência e Impedância) figura 15

1 ciclo após a falta						2 ciclo após a falta						
Vmedio	Imedio	Zmedia	Pmedio	Vinst	linst	Vmedio	Imedio	Zmedia	Pmedio	Zinst	Vinst	linst
x	x					x	x					

Figura 15 – Modelo do sistema de transmissão

Afim de verificar a falha no espectro de frequência é preciso valer-se de técnicas para gerar o espaço amostral. Amostrar um sinal é um termo herdado da teoria de processamento de sinais e se refere ao processo no qual se converte um sinal contínuo no tempo em uma sequência numérica. Este processo é feito a uma determinada frequência, denominada *Frequência de Amostragem* (SILVA L. R. B.; BERTACHI, 2013).

A ferramenta matemática empregada neste caso é o teorema de Nyquist, que diz: a quantidade de amostras capturadas por unidade de tempo de um sinal deve ser feita a uma frequência de amostragem superior ao dobro da maior frequência contida no sinal amostrado. Assim o sinal original amostrado pode ser reconstruído integralmente sem erro de Aliasing. Prezando por uma grande precisão na tarefa da estima dos fatores, os algoritmos tradicionalmente empregados são: Transformada Discreta de Fourier TDF e Transformada Discreta Cosseno - TDC. Ambas necessitam que a janela de dados seja escolhida de forma que a quantidade de amostras corresponda a uma quantidade inteira de ciclos da frequência fundamental (DINIZ; SILVA; NETTO, 2014).

A janela de dados da falha é dada pelo conceito de dados transitórios e obtida através de duas janelas pós falha, normalizadas para tensão média, corrente média, impedância média, potencia média, tensão instantânea e corrente instantânea. Conceito que pode ser visto na figura 19 que exemplifica o conceito de janela móvel, com janelas contendo valores dos períodos pré e pós-falha..

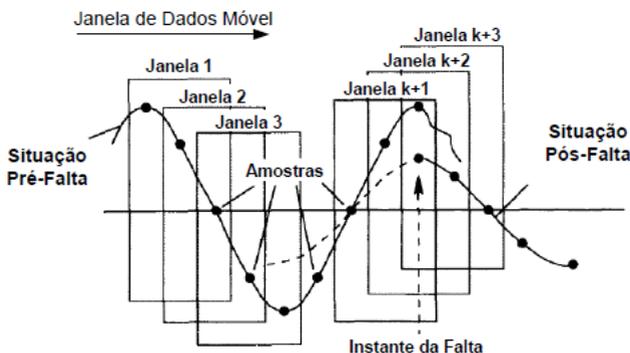


Figura 16 – Janela de móvel de Dados

Fonte: (DINIZ; SILVA; NETTO, 2014)

5.1.2 Condições de Curto-Circuito

Após uma detalhada análise das falhas no capítulo anterior, opta-se pelas falhas assimétricas e para obtenção de um número satisfatório de condições de falha que permitisse analisar a eficiência do algoritmo proposto, foram então simulados os cinco tipos de falhas assimétricas citados no capítulo 4 seguindo os critérios descritos na tabela 1 retirada de (CRUZ, 2005).

Considerações da simulação	Conjunto 1
Tipo de Falha	AT, BT, CT, AB, AC, BC, ABT, BCT, ACT, ABC e ABCT
Localização da Falha (%)	0, 10, 20, 30, 40, 50, 60, 70, 80, 90 e 100% em relação ao local de análise
Ângulo de incidência da falha (°)	0° e 90°
Resistência	0, 10 e 20

Tabela 1 – Parâmetros gerados para definição da arquitetura das RNA

Após confirmada a ocorrência de falha, a etapa seguinte é o reconhecimento das fases envolvidas no curto-circuito. Aqui de fato entra nosso trabalho, uma RNA de classificação com duas camadas ocultas

	RNA 1	RNA 2
Aprendizado	Supervisionado	Supervisionado
Treinamento	Backpropagation	Backpropagation
Número de Camadas Ocultas	2	0
Função de Ativação da Camada Oculta	Tansig	-
Função de Ativação da Camada de Saída	Purelin	Purelin

Tabela 3 – Características das duas RNAs utilizadas na classificação de falhas

24 e 12 neurônios e uma segunda rede configurada com o Algoritmo Genético. Na tabela 2 estão as saídas desejadas na classificação de cada tipo de falha.

Tipo de Falha	Fase A	Fase B	Fase C	Terra
AT	1	0	0	1
BT	0	1	0	1
CT	0	0	1	1
AB	1	1	0	0
AC	1	0	1	0
BC	0	1	1	0
ABT	1	1	0	1
BCT	0	1	1	1
ACT	1	0	1	1
ABC	1	1	1	0
ABCT	1	1	1	1

Tabela 2 – Combinações para as saídas da RNA de classificação

Após delimitadas as saídas e entradas da rede defini-se a arquitetura, tabela 3, a ser utilizada na classificação das amostras.

5.2 EXPERIMENTO

Neste capítulo são apresentados os resultados das simulações realizadas para as RNAs moeladas. Este trabalho propõe a análise e

comparação de duas RNAs para o processo de classificação de falhas, que inclui os aspectos relacionados aos dois quadros subsequentes ao momento de falha. A ferramenta MatLab por meio da Toolbox Neural Network foi utilizada para elaboração, testes, treinamentos e validações das RNAs. O conjunto de entradas, dados de tensão, foram criados com base nos vetores de tensão do trabalho de Cruz (2005), e contam com 1320 pontos, cada um com 12 características. O que constitui nosso vetor de entrada, gerado a partir das simulações do sistema elétrico.

A rede recebe como parâmetros de treinamento três vetores de tamanho igual 1320X12, para estabelecer os critérios iniciais e fazer a calibragem da rede: bias e pesos sinápticos. Destes apenas um deles é de fato vetor de entrada da rede, os outros dois são apenas utilizados no treinamento da rede. O treinamento da rede foi dividido em três grupos a fim de evitar o "overtraining", para cada conjunto de treino um vetor de padrões foi utilizado. A divisão de dados ficou 70% para treinamento 30% para validação. A validação também conta com três vetores alvos de saídas desejadas (TARGETS), seguindo a mesma lógica dos vetores de padrões apenas um é utilizado na inicialização da rede. Os outros dois fazem parte do grupo de testes.

A segunda RNA foi modelada a partir do uso de AGs proposto por (SANTOS et al., 2016). A principal vantagem do AG, se comparada com a rede 1 é que o AG procura os melhores resultados nos potenciais dos indivíduos da população. Existe mais de uma forma de interagir com o AG, neste caso: O AG seleciona os parâmetros, as regras de aprendizagem, as funções de treinamento, as funções de transferência, os pesos e bias da rede final otimizada.

Para estimativa da segunda RNAs, foram configurados os parâmetros do AG :tamanho da população, número de gerações, taxa de mutação, quantidade máxima de neurônios por camada, número de camadas ocultas, funções de transferência e função de treinamento.

Outra característica que merece destaque, diferente da primeira RNA que foi fiel à realidade, nesta existe a normalização dos dados de entrada. Segundo Haykin (2000) para minimizar o tempo de aprendizagem, deve-se evitar o uso de entradas com média diferente de zero. Para tanto é importante salientar que com dados $[0,1]$ a rede permite que neurônios assumam valores entre $[-1, 1]$ o que pode produzir uma convergência mais rápida do que por um processo similar com funções de ativação não-simétricas.

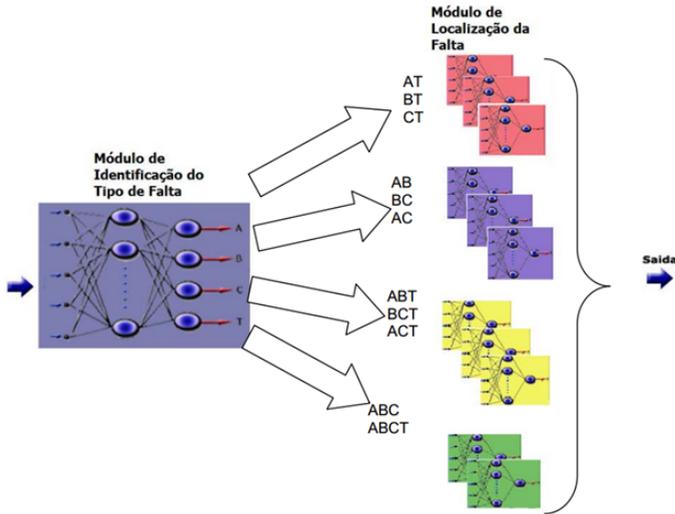


Figura 17 – Representação gráfica do conjunto de classificação

5.3 RESULTADOS

Da mesma forma que demonstrado por SILVA L. R. B.; BERTACHI (2013) a classificação de falhas por uma RNA com arquitetura simples é possível, de forma a obter um alto índice de satisfação em relação ao objetivo desejado. Porém o tempo de treinamento da rede pode ser considerado mais elevado quando comparado com uma RNA híbrida, que teve sua arquitetura "desenhada" por um algoritmo genético. ALMEIDA et al. (2004) apresenta um AG que permite maior eficiência do processo, alcançando-se soluções otimizadas e em menor número de gerações, em função do problema a ser tratado e da codificação utilizada para o algoritmo genético. A utilização de codificações melhores, isto é, mais adaptadas ao problema, tende a levar os AGs a obterem soluções melhores em menor tempo de processamento.

As duas redes testadas convergem para o resultado esperado, de acordo com os padrões de entrada, que são os mesmos para ambas. A rede número 1, executada dentro de um laço *for* com cinco iterações, mil épocas por iteração e duzentas validações por iteração apresentou como resultado:

MSE (Erro Médio)	RMSE (Erro Médio Quadrado)	Média_ABCT Média da Saída
1.5351	1.2390	0.8241
3.9625	1.9906	1.0714
0.7365	0.8582	0.3766
1.7018	1.3045	0.7996
0.8918	0.9443	0.4740

Tabela 4 – Indicadores da RNA 1

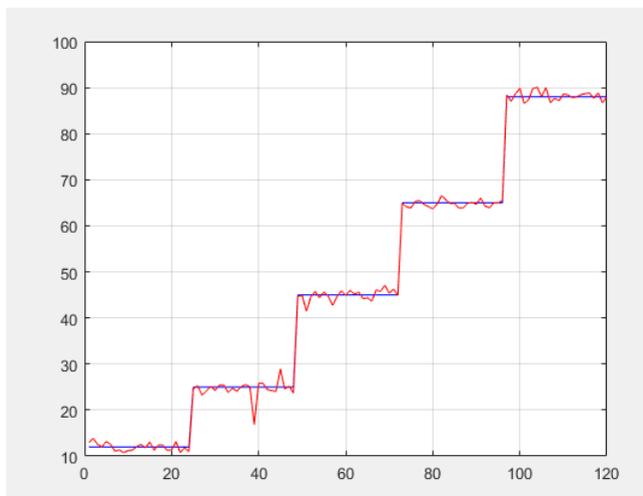


Figura 18 – Comparação entre a saída desejada e a saída real - teste 1

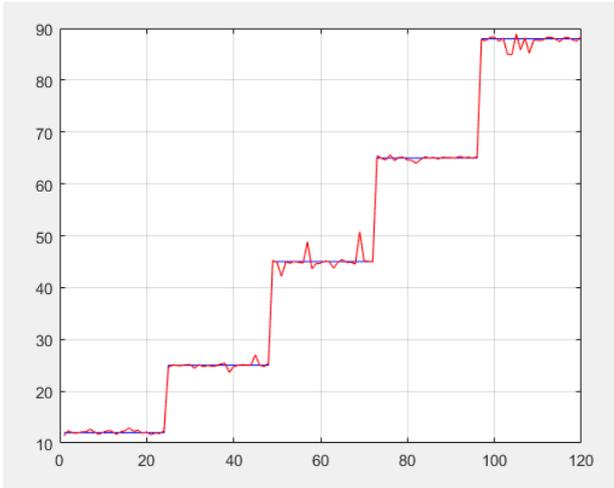


Figura 19 – Comparação entre a saída desejada e a saída real - teste 5

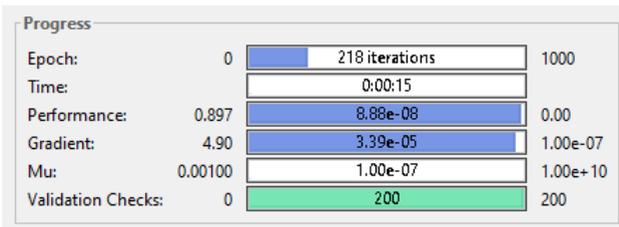


Figura 20 – Indicadores da RNA 1 ao final do 5º teste

É possível verificar na figura 20 que a rede convergiu para seu melhor desempenho antes do término das mil épocas programadas para a última das cinco iterações. Apresentando um Erro médio (MSE) igual a 1,7665 verificado na tabela 4, o que resultou em um baixo desempenho, apenas 8,0685.

Para a segunda rede neural testada, o algoritmo genético de Santos et al. (2016) foi alimentado com os padrões limítrofes para geração da melhor RNA de classificação, pode ser observado na tabela 5:

Parâmetros	Valores
Tamanho da População	100
Número de Gerações	100
Taxa de Mutação	0.4
Quantidade Máxima de Neurônios por Camada	30
Funções de Transferência	logsig, tansig, purelin
Função de Treinamento	trainlm
Quantidade Máxima de Camadas Internas	3

Tabela 5 – Parâmetros limítrofes da RNA 2

Após quatro horas de iterações do AG buscando a melhor RNA de classificação, a rede gerada apresenta 12 entradas, três camadas 21-25-10 e 10 neurônios na saída como, mostra a figura 21.

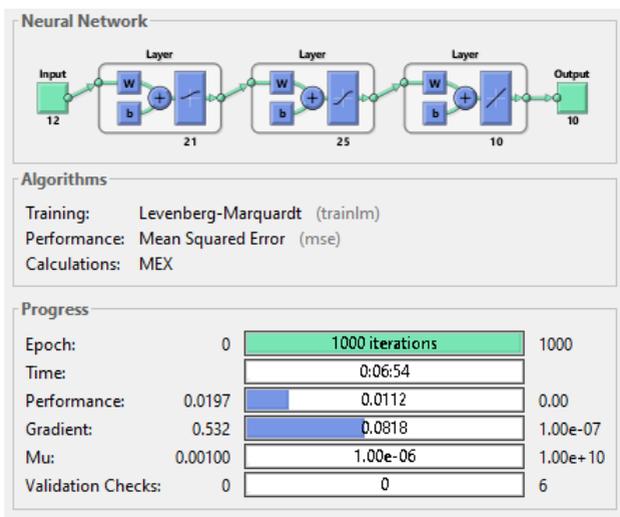


Figura 21 – Indicadores da RNA 2 ao término da validação

Consequência da melhor estrutura da Rede 2, o desempenho calculado foi 23,6732, muito superior a rede 1 o que deixa evidente o papel fundamental do algoritmo genético para construção e escolha de parâmetros de uma RNA. Por fim o erro médio encontrado na rede figura 22 é extremamente inferior à rede 1, $MSE = 0,011218$.

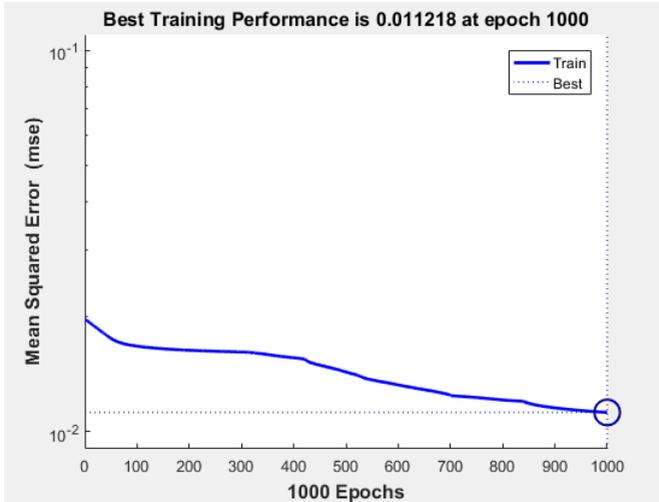


Figura 22 – Erro médio da RNA 2

Considerando as arquiteturas utilizadas para classificação das falhas na rede de energia e os trabalhos utilizados como base, o trabalho demonstra que a utilização de algoritmos genéticos para elaboração de estrutura de RNA é superior. Pois apresentou um melhor desempenho tanto no tocante a literatura citada quando nas simulações realizadas como fica demonstrado na tabela 6

	RNA 1	RNA 2
Camadas	24-12-12	21-25-10
Número de épocas	1000	1000
Performace	8,0685	23,6732
Erro (MSE)	1,7665	0,011218

Tabela 6 – Comparação da performance das RNAs

6 CONCLUSÃO E TRABALHOS FUTUROS

O presente trabalho através das pesquisas realizadas nas áreas de Smart Grids, Redes Neurais Artificiais (RNA), gerenciamento e classificação de falhas em sistemas de energia demonstra que é possível o uso destas técnicas para aprimorar os sistemas de gerenciamento de falhas. Entre as contribuições acadêmicas do trabalho pode ser destacada a comparação de duas RNAs para classificação as falhas e determinar qual a melhor RNA. E desta forma, confirmar que tais técnicas são plenamente viáveis para a utilização neste tipo de sistema.

De acordo com os artigos pesquisados (GUNGOR; LU; HANCKE, 2010) é demonstrado no presente trabalho, que a RNA porposta pelo uso de algoritmos genéticos tem superioridade na obtenção de resultados, tanto por convergir em um menor tempo, quanto por apresentar uma performance melhor. Desse modo, o classificador de falhas definido como melhor na comparação realizada é capaz de integrar um sistema de proteção para redes elétricas, acoplado a um módulo de localização de falhas em uma rede física de energia: constitui uma importante ferramenta para gerenciar uma rede de energia elétrica.

Tomando como base os problemas encontrados durante o desenvolvimento deste trabalho: dificuldade de obtenção dos dados e dificuldade na obtenção de trabalhos semelhantes para compor a fundamentação teórica. Fica como sugestão para trabalhos futuros a implementação de uma RNA para localizar as falhas e também uma RNA para tomada de decisão pós falhas. Dispositivo que se embarcado, juntamente com um microcontrolador e um módulo de GPS pode constituir um produto para comercialização no mercado de energia.

REFERÊNCIAS

- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL. Procedimentos de distribuição de energia elétrica no sistema elétrico nacional - PRODIST. *Módulo 8 - Qualidade da energia elétrica, Revisão 7, Brasília*, 2016.
- ALMEIDA, P. et al. Utilização de algoritmo genético na parametrização de redes neurais artificiais para aplicação na elaboração de orçamento de vendas. *Anais do Enanpad*, 2004.
- AMIN, S. M.; WOLLENBERG, B. F. Toward a smart grid: power delivery for the 21st century. *IEEE power and energy magazine*, IEEE, v. 3, n. 5, p. 34–41, 2005.
- ATA, R. Artificial neural networks applications in wind energy systems: a review. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 49, p. 534–562, 2015.
- BANGALORE, P.; TJERNBERG, L. B. An approach for self evolving neural network based algorithm for fault prognosis in wind turbine. In: IEEE. *PowerTech (POWERTECH), 2013 IEEE Grenoble*. [S.l.], 2013. p. 1–6.
- BOSE, A. Smart transmission grid applications and their supporting infrastructure. *IEEE Transactions on Smart Grid*, IEEE, v. 1, n. 1, p. 11–19, 2010.
- BRAGA, A. de P. *Redes neurais artificiais: teoria e aplicações*. LTC Editora, 2007. ISBN 9788521615644. <<https://books.google.com.br/books?id=R-p1GwAACAAJ>>.
- BRESSAN, N. et al. The deployment of a smart monitoring system using wireless sensor and actuator networks. In: IEEE. *Smart Grid Communications (SmartGridComm), 2010 First IEEE International Conference on*. [S.l.], 2010. p. 49–54.
- CRUZ, I. *Eletrônica de potência: introdução ao estudo dos conversores CC-CA*. [S.l.]: Edição dos Autores, 2005.
- DINIZ, P. S.; SILVA, E. A. da; NETTO, S. L. *Processamento Digital de Sinais-: Projeto e Análise de Sistemas*. [S.l.]: Bookman Editora, 2014.

DUTRA, R. M. O.; SPERANDIO, M.; COELHO, J. O método ward de agrupamento de dados e sua aplicação em associação com os mapas auto-organizáveis de Kohonen. *I Workcomp Sul*, p. 1–12, 2004. <<http://inf.unisul.br/ines/workcomp/>>.

ENERGIA, M. d. M. e. E. Relatório smart grid do grupo de trabalho de redes elétricas inteligentes. *Mme*, 2012.

FANG, X. et al. Smart Grid — The New and Improved Power Grid: A Survey. *IEEE Communications Surveys & Tutorials*, v. 14, n. 4, p. 944–980, 2012. ISSN 1553-877X. <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6099519>>.

GUERRA, S.; PRUDÊNCIO, R.; LUDERMIR, T. Meta-aprendizado de algoritmos de treinamento para redes multi-layer perceptron. In: *Anais do XXVII Congresso da Sociedade Brasileira de Computação. Rio de Janeiro: Citeseer*. [S.l.: s.n.], 2007. p. 1022–1031.

GUNGOR, V. C.; LU, B.; HANCKE, G. P. Opportunities and challenges of wireless sensor networks in smart grid. *IEEE transactions on industrial electronics*, IEEE, v. 57, n. 10, p. 3557–3564, 2010.

GUOLIAN, H. et al. Research on fault diagnosis of wind turbine control system based on artificial neural network. In: *IEEE. Intelligent Control and Automation (WCICA), 2010 8th World Congress on*. [S.l.], 2010. p. 4875–4879.

GUTIÉRREZ, J. A. et al. Applying wireless sensor networks in industrial plant energy evaluation and planning systems. In: *IEEE. Conference Record of 2006 Annual Pulp and Paper Industry Technical Conference*. [S.l.], 2006. p. 1–7.

HART, D. G. Using ami to realize the smart grid. In: *2008 IEEE Power and Energy Society General Meeting—Conversion and Delivery of Electrical Energy in the 21st Century*. [S.l.: s.n.], 2008.

HAYKIN, S. *Redes Neurais - Princípios e Prática - 2ª Ed..pdf*. 2001.

HAYKIN, S. S. *Redes neurais artificiais: princípio e prática. 2ª Edição, Bookman, São Paulo, Brasil*, 2000.

HERNANDEZ, L. et al. A multi-agent system architecture for smart grid management and forecasting of energy demand in virtual power plants. *IEEE Communications Magazine*, IEEE, v. 51, n. 1, p. 106–113, 2013.

IN, N. The ETP SmartGrids presents :. n. April, 2015.

Instituto Acende Brasil. Qualidade do Fornecimento de Energia Elétrica: Confiabilidade, Conformidade e Presteza. *Instituto Acende Brasil*, p. 1–36, 2014.

KRAUSE, J. C. R. Eric de A. Desenvolvimento de algoritmo genético para otimização de arquiteturas de redes neurais artificiais. *XXVII Congresso de Iniciação Científica da Unesp*, 2015.

LEMOS, J. et al. Sistema híbrido para monitormamento, diagnose e detecção de falhas em motores de indução. In: *CINDUSCON: VII Conferência Internacional de Aplicações Industriais, Poços de Caldas-MG*. [S.l.: s.n.], 2008.

LEN, R. A.; VITTAL, V.; MANIMARAN, G. Application of sensor network for secure electric energy infrastructure. *IEEE Transactions on Power Delivery*, IEEE, v. 22, n. 2, p. 1021–1028, 2007.

LOPES, Y.; FERNANDES, N. C.; CHRISTINA, D. M. Geração Distribuída de Energia: Desafios e Perspectivas em Redes de Comunicação. *Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, p. 2–55, 2015.

LU, Z.-g. et al. Distributed agent-based state estimation considering controlled coordination layer. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 54, p. 569–575, 2014.

MUNÁRRIZ, L. Á. *Fundamentos de inteligencia artificial*. [S.l.]: Editum, 1994.

MÁSSON, E.; WANG, Y.-J. Introduction to computation and learning in artificial neural networks. *European Journal of Operational Research*, v. 47, n. 1, p. 1 – 28, 1990. ISSN 0377-2217. <<http://www.sciencedirect.com/science/article/pii/037722179090085P>>.

OLESKOVICZ, M.; COURY, D.; AGGARWAL, R. O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, SciELO Brasil, v. 14, n. 2, p. 138–150, 2003.

OPRISAN, M. et al. A reliability data system for the reporting of forced outages of distribution equipment. In: *IEEE WESCANEX'91'IEEE Western Canada Conference on Computer, Power and Communications Systems in a Rural Environment'*. [S.l.], 1991. p. 267–270.

PINTO, T. D. S. O apagão energético de 2001.

QUEIROZ, L. M. O. de. Estimaco e anlise das perdas tcnicas na distribuico de energia eltrica. p. 155, 2010.

RAZA, M. Q.; KHOSRAVI, A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 50, p. 1352–1372, 2015. ISSN 18790690. <<http://dx.doi.org/10.1016/j.rser.2015.04.065>>.

REE, J. D. L. et al. Synchronized phasor measurement applications in power systems. *IEEE Transactions on Smart Grid*, IEEE, v. 1, n. 1, p. 20–27, 2010.

RIEKEN, D. W.; II, M. R. W. Ultra low frequency power-line communications using a resonator circuit. *IEEE Transactions on Smart Grid*, IEEE, v. 2, n. 1, p. 41–50, 2011.

SAMADI, P. et al. Optimal real-time pricing algorithm based on utility maximization for smart grid. In: IEEE. *Smart Grid Communications (SmartGridComm), 2010 First IEEE International Conference on*. [S.l.], 2010. p. 415–420.

SANTIS, E. D. et al. A learning intelligent system for fault detection in smart grid by a one-class classification approach. In: *2015 International Joint Conference on Neural Networks (IJCNN)*. [S.l.: s.n.], 2015. p. 1–8. ISSN 2161-4393.

SANTOS, R. C. dos et al. Rede neural artificial otimizada para classificaco de cncer de mama. *Journal of Health Informatics*, v. 8, p. 299–308, 2016.

SCHLECHTINGEN, M.; SANTOS, I. F. Comparative analysis of neural network and regression based condition monitoring approaches for wind turbine fault detection. *Mechanical systems and signal processing*, Elsevier, v. 25, n. 5, p. 1849–1875, 2011.

SILVA, L. R. B. *Classificaco de falhas em maquinas eletricas usando redes neurais, modelos wavelet e medidas de informaco*. Dissertaco (Mestrado) — Universidade Tecnolgica Federal do Paran, 2014.

SILVA L. R. B.; BERTACHI, A. H. S. H. L. S. P. R. G. A. Classification of voice pathologies based on neural networks and predictability measures. *XI Simpsio Brasileiro de Automaco Inteligente (SBAI'2013)*., 2013.

TRONCHONI, A. B. Identificação de causas de desligamentos não programados em redes de distribuição. 2008.

TSODYKS, M.; GILBERT, C. Neural networks and perceptual learning. *Nature*, Nature Publishing Group, v. 431, n. 7010, p. 775–781, 2004.

YANG, S.; LI, W.; WANG, C. The intelligent fault diagnosis of wind turbine gearbox based on artificial neural network. In: IEEE. *Condition Monitoring and Diagnosis, 2008. CMD 2008. International Conference on*. [S.l.], 2008. p. 1327–1330.

YOU, X.; ZHANG, W. Fault diagnosis of frequency converter in wind power system based on som neural network. *Procedia Engineering*, Elsevier, v. 29, p. 3132–3136, 2012.

ZAMBONI, L. *Detecção e localização de faltas em sistemas elétricos de distribuição usando abordagem inteligente baseada em análise espectral de sinais*. Tese (Doutorado) — Universidade de São Paulo, 2013.

ZHANG, P.; LI, F.; BHATT, N. Next-generation monitoring, analysis, and control for the future smart control center. *IEEE Transactions on Smart Grid*, IEEE, v. 1, n. 2, p. 186–192, 2010.