

Utilização de RNAs para o Monitoramento Remoto das Tensões Frente a Diferentes Perfis de Carga em um Sistema de Distribuição

Rodolfo Takeshi Ota, Mário Oleskovicz, Fernando Bambozzi Bottura, Daniel Ferreira Lima.

Universidade de São Paulo (USP), Escola de Engenharia de São Carlos (EESC)

rodolfo.ota@usp.br, olesk@sc.usp.br, fernando.bottura@usp.br, daniel.ferreira.lima@usp.br

Resumo — A presente pesquisa visa apresentar um método de monitoramento remoto utilizando redes neurais artificiais. Sendo assim, serão estimados os valores das tensões trifásicas em diversos pontos de um sistema de distribuição primário, considerando diferentes perfis de carga. A modelagem de um sistema de distribuição real via o *software ATP (Alternative Transients Program)* possibilitou o treinamento e a validação das redes neurais artificiais. Os resultados obtidos ilustram que a metodologia de monitoramento remoto apresenta desempenho adequado e pode ser uma alternativa e/ou complemento ao plano de monitoramento da qualidade de energia nos sistemas de distribuição.

Palavras-chaves — Sistemas de Distribuição, Qualidade da Energia Elétrica, Redes Neurais Artificiais, Monitoramento Remoto da Tensão.

I. INTRODUÇÃO

A Qualidade da Energia Elétrica (QEE) é caracterizada por temas que englobam problemas manifestados na tensão, corrente ou desvio de frequência que causam prejuízos para os consumidores finais, principalmente nos setores comercial e industrial. Dentre os principais efeitos indesejados tem-se a parada de equipamentos, oscilações luminosas, perda de memória em microprocessadores, mau funcionamento e diminuição da vida útil de motores, [1].

Dada a importância da QEE, as concessionárias devem fornecer energia elétrica dentro dos padrões de qualidade que regulam a conformidade da forma de onda da tensão, a continuidade do fornecimento de energia elétrica e o atendimento ao consumidor [2].

A falta da QEE pode ser decorrente da presença de distúrbios (descontinuidades) nos sinais das tensões e correntes trifásicas e/ou na frequência fundamental do sistema. Alguns dos distúrbios associados à falta da QEE são: transitórios oscilatórios e impulsivos; Variações de Tensão de Curta e Longa Duração (VTCDs e VTLDs, respectivamente); distorção harmônica; dentre outros [1].

Uma maneira de minimizar os distúrbios e os prejuízos decorrentes da falta de QEE consiste no aumento do número

de medições ao longo do o Sistema de Distribuição (SD) de interesse, garantindo maior conhecimento a respeito de seu comportamento. Tais medições viabilizam ações que podem inibir a propagação de tais distúrbios no SD e os consequentes danos ao consumidor. Entretanto, esse aumento no número de medidas sobre o SD apresenta vários entraves, tais como: escolha do equipamento adequado; local para instalação do equipamento; determinação do número de medidores; cuidados no armazenamento e processamento dos dados obtidos.

Além disso, muitas análises sobre a QEE exigem um longo período de monitoramento do sistema elétrico para a obtenção de registros representativos e consistentes. [1]. Logo, faz-se necessário o constante aprimoramento dos métodos de medição e análise do SD, de modo a se transpor tais dificuldades técnicas.

Vale comentar que o contexto acima apresentado vem ao encontro dos principais conceitos e filosofias relacionadas às *Smart Grids* (SGs) (redes elétricas inteligentes). Dentre os princípios associados às SGs, busca-se uma maior automação dos sistemas e processos, um aumento da eficácia energética e da confiabilidade dos sistemas elétricos de potência [3]. Neste sentido, a atual literatura conta com diversos trabalhos envolvendo o monitoramento remoto do SD e técnicas de inteligência artificial. A pesquisa reportada em [4] consiste em um protótipo de um instrumento para o monitoramento da QEE através da análise dos índices de continuidade de um conjunto de consumidores através de um micro controlador. Já em [5] os autores direcionaram seus esforços na construção de um protótipo de medidor de baixo custo que atendesse às especificações de [6]. Em [7], foram realizadas análises de aspectos práticos referentes ao desempenho de Redes Neurais Artificiais (RNAs) em sistemas de potência, considerando os diferentes tipos de arquitetura, métodos de treinamento, número de neurônios e demais variáveis. Além disso, a utilização de RNAs no contexto do monitoramento remoto da tensão também foi abordada por [8] e [9], onde foram utilizadas redes do tipo *Perceptron* Multicamadas (PMC). Em [9], o autor efetuou um tratamento prévio em seu banco de dados, agrupando dados com características semelhantes de forma a gerar informações abrangentes e diminuir o vetor de entrada das RNAs.

Neste sentido, a presente pesquisa utilizará de RNAs do tipo PMC para realizar o monitoramento remoto da tensão em um SD. Apesar de a pesquisa ser baseada em simulações

Os autores gostariam de agradecer ao Laboratório de Sistemas de Energia Elétrica (LSEE), da Escola de Engenharia de São Carlos (EESC- USP) pela infraestrutura proporcionada, assim como à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo suporte financeiro disponibilizado para a realização desta pesquisa.

computacionais, deseja-se analisar seu desempenho e índice de acertos para uma possível aplicação futura em campo. Sendo assim, é imprescindível que as etapas de modelagem do SD e geração do banco de dados sejam efetuadas de forma a abranger o maior número de casos possível, aproximando-se das situações reais de operação do SD. Para isso, foi compilado um amplo banco de dados a ser utilizado na fase de treinamento das RNAs, o qual contém informações referentes as simulações das situações de curtos-circuitos em diferentes pontos do SD, considerando-se três perfis distintos de carga.

Vale ressaltar que o monitoramento remoto via RNAs, realizado a partir da Subestação de Energia (SE) do SD visa proporcionar à concessionária de energia uma considerável economia de recursos técnico-financeiros, visto que tal procedimento poderá complementar as medições já realizadas em campo e consiste em uma continuação dos trabalhos de [10]-[12].

II. PERFIS DE CARGA

O conhecimento da demanda energética dos consumidores do sistema elétrico brasileiro é fator de extrema importância, tanto em questões relacionadas ao investimento e planejamento da tarifação [13], quanto para uso em simulações que melhor representem o comportamento de um SD real, sendo este último o foco deste trabalho.

Como fato da operação do Sistema Elétrico de Potência (SEP), tem-se que a potência fornecida pelas distribuidoras de energia é consumida de forma variável durante o dia. Dessa forma, a demanda das cargas presentes no SD não possui caráter estático, sendo necessário o conhecimento dos perfis de carga dos consumidores. A partir das curvas de carga é possível, por exemplo, o aumento e diminuição das cargas envolvidas no SD no decorrer do dia, obtendo-se os valores mínimos e máximos de carga a serem utilizados nas simulações. Com isso, é possível estimar a efetividade do modelo proposto em diversas situações de operação.

Conforme apontado por [14], os consumidores industriais respondem por cerca de 60% de toda a energia elétrica consumida no território nacional. Entretanto, as curvas de carga do setor industrial possuem características diversas quando se analisa cada ramo de atividade econômica. Dessa forma, [14] organizou os perfis de carga por grupos de indústrias com perfis semelhantes. Como resultado, obteve valores de potência desde zero, no caso do fechamento da indústria em determinados horários do dia, até valores de aproximadamente de 60% da carga máxima, conforme pode ser observado na Fig. 1.

Com base nos resultados apresentados em [14], foram definidos para esta pesquisa os seguintes valores de carga: mínimo de 10% da potência instalada (valor máximo de carga) e máximo de 100% da potência instalada de cada consumidor.

Os valores utilizados são justificados pelo objetivo inicial desta pesquisa, que consistiu em estabelecer valores de carga máxima e mínima para o SEP, de maneira a verificar a efetividade da utilização dos modelos de RNAs submetidos a diferentes perfis de carga do SEP. Sendo assim, cada

indústria pode adquirir como valor máximo somente o equivalente a sua potência instalada em situações de acionamento simultâneo de todos os seus equipamentos, e o valor mínimo de zero, adquirido no fechamento da indústria. Entretanto, foi adotado como perfil de carga mínima um valor levemente superior (10%) devido ao fato de que algumas indústrias não fecham por completo no decorrer do dia, conforme explicitado nos estudos de [14].




Fig. 1. Curva de carga do setor industrial. Fonte: [14].

III. REDES NEURAIS ARTIFICIAIS

As redes do tipo PMC utilizadas no presente trabalho possuem duas camadas escondidas, conforme ilustrado na Fig. 2. A camada de entrada é composta pelos sinais de tensão e corrente trifásicos obtidos na SE. Foram adotadas duas camadas intermediárias com vinte neurônios cada, pois segundo [12] esta topologia apresentou os melhores resultados ao fim de seus estudos. Já a camada de saída apresentará a resposta da rede frente ao problema analisado, caracterizada por um neurônio. Dessa forma, cada RNA apresentará um valor de tensão monofásico em um ponto de monitoramento escolhido. Assim, conforme será apresentado, serão necessárias três RNAs para a obtenção do valor de tensão trifásico no ponto a ser monitorado.




Fig. 2. Topologia da RNA utilizada para o monitoramento remoto.

IV. SIMULAÇÃO COMPUTACIONAL

O SD analisado foi previamente modelado via o software *Alternative Transients Program* (ATP) [9], por meio da

interface gráfica *ATPDraw* como resultado de uma cooperação entre o Laboratório de Sistemas de Energia Elétrica (LSEE) da Escola de Engenharia Elétrica (EESC-USP) e uma concessionária de energia regional. A fonte de tensão empregada na simulação é uma fonte senoidal trifásica tipo 14 [9] e seus parâmetros para a fase A são apresentados na Tabela I. Dado que o sistema empregado é ABC, os valores das demais fases podem ser obtidos.

TABELA I. PARÂMETROS DA FONTE UTILIZADA.

Parâmetros	Valor
Amplitude	71.851,699 V
Frequência	60 Hz
Fase	0°

De acordo com o modelo RL mutuamente acoplado [9], a modelagem necessita de uma impedância em série com a fonte de tensão. Sendo assim, os valores de impedância de sequência zero e positiva do modelo acima podem ser observados na Tabela II.

TABELA II. PARÂMETROS DO MODELO RL MUTUAMENTE ACOPLADO, EM SÉRIE COM A FONTE DE TENSÃO.

Parâmetro	Valor
Resistência de sequência zero	20,805 Ω /m
Indutância de sequência zero	203,721 mH/m
Resistência de sequência positiva	4,062 Ω /m
Indutância de sequência positiva	52,5397 mH/m

Por fim, para o transformador presente na subestação foi considerado um modelo trifásico saturável com dois enrolamentos [9], com conexão entre o primário e secundário do tipo Y- Δ . Seus parâmetros são mostrados na Tabela III.

TABELA III. PARÂMETROS DO TRANSFORMADOR DE POTÊNCIA DA SUBESTAÇÃO

Parâmetro	Valor
Potência nominal	15/20 MVA
Relação de transformação	3,809524
Corrente nominal no primário	131,215970 A
Corrente nominal no secundário	499,870363 A
Deslocamento angular	30°
Resistência do primário	0,054695 Ω
Resistência do secundário	0,79376 Ω
Indutância do primário	1,628 mH
Indutância do secundário	23,6258 mH
Resistência de magnetização	1 M Ω

A geração do banco de dados foi realizada no próprio *ATP*, onde os valores das cargas foram adaptados para os diferentes perfis, conforme explicado na seção II. Essa adaptação consistiu na adoção dos valores equivalentes a 10% da potência instalada; o valor da demanda contratada, ou seja, um percentual da potência instalada (que varia de acordo com o tipo de indústria); e 100% da potência instalada, caracterizando cargas leves, médias e pesadas, respectivamente. Para todas as cargas foi considerado um fator de potência indutivo igual a 0,96.

Durante as etapas de alteração dos valores das cargas, tomou-se o cuidado para que as novas simulações representassem com a maior fidelidade possível o SD real.

A necessidade ou não de se utilizar reguladores de tensão foi verificada através da constante simulação do fluxo de potência do SD em análise. Ou seja, para cada alteração dos valores das cargas foi realizada uma simulação do SD em condições normais de operação (regime permanente), medindo-se a tensão trifásica em todos os pontos do sistema. Os reguladores de tensão foram inseridos na modelagem sempre que o valor da tensão adquiriu valor inferior a 0,9 p.u. em qualquer ponto do SD em análise. Normalmente, a regulação de tensão é realizada através de reguladores de tensão ou transformadores reguladores, comumente instalados no barramento da subestação, ou também ao longo das linhas [15]. Para o presente projeto, considerou-se a utilização de transformadores ideais para a realização da regulação de tensão.

Após a definição do valor de todas as cargas a serem inseridas no SD, foi necessário definir o domínio de operação das RNAs, que representam as situações nas quais o sistema elétrico analisado poderá estar submetido no decorrer do tempo. Este cenário é caracterizado pela ocorrência de afundamentos de tensão devido aos curtos-circuitos incidentes.

Para isso, foram considerados diferentes impedâncias e ângulos de inserção dos curtos-circuitos, bem como diferentes perfis de carregamento. Vale ressaltar que quanto aos tipos de faltas, foram consideradas: faltas monofásicas envolvendo as fases A, B e C com conexão a terra, faltas bifásicas entre as fases A e B com e sem conexão com a terra, faltas bifásicas entre as fases A e C com e sem conexão com a terra, faltas bifásicas entre as fases B e C com e sem conexão com a terra e faltas trifásicas com e sem conexão com a terra. Já em relação ao ângulo de incidência da falta, foram adotados os ângulos de 0° e 90°, com impedâncias de falta variando entre os valores de 0, 10, 20, 30 e 40 Ω .

Por fim, foram selecionados 20 pontos para a aplicação das faltas sobre o SD em análise (*PF1*, *PF2*,..., *PF20*) e 6 pontos de monitoramento (*Mn1*, *Mn2*,..., *Mn6*). Todos estes pontos foram escolhidos de forma a abranger de maneira mais ampla possível o SD.

V. TRATAMENTO DOS DADOS E UTILIZAÇÃO DAS RNAs

Após a realização de todas as simulações referentes aos diferentes perfis de carga e de falta, foram obtidos 6.600 padrões para serem utilizados como banco de dados. Os dados de saída do *software ATP* foram configurados para fornecer como resultado as formas de onda amostradas das tensões trifásicas nos seis pontos de monitoramento, bem como as formas de onda das tensões e correntes trifásicas na SE. Todos os sinais foram amostrados de forma a se obter 128 valores por ciclo de onda, ou seja, cada ciclo da senóide é representado computacionalmente por 128 amostras.




Fig. 3. Posicionamento dos pontos de aplicação das situações de faltas (PF1 a PF20), monitoramento (Mn1 a Mn6) e da subestação de energia (SE) no SD.

Em seguida, realizou-se o recorte das formas de onda fornecidas pelo *software ATP*, selecionando-se a porção da onda que continha os dados mais significativos para as RNAs. Este recorte selecionou 9 ciclos de onda, sendo 3 de pré-falta, e 6 de pós falta. Após o recorte de todas as formas de ondas, foi aplicada uma janela deslizante com dimensão de um ciclo e deslocamento de meio ciclo, sendo calculado o valor eficaz da forma de onda (X_{RMS}) a cada deslocamento da janela. Este cálculo foi realizado conforme (1), onde (x_i) são os pontos amostrados da tensão ou corrente, e N representa o número de valores amostrados.

$$X_{RMS} = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N x_i^2} \quad (1)$$




Fig. 4. Janela deslizante aplicada sobre os sinais trifásicos em análise.

Dessa forma, foram obtidos 17 valores RMS para cada situação, sendo seis de pré-falta e 11 de pós falta. Assim, o

banco de dados para as RNAs é composto por 6.600 casos, cada caso contendo 17 valores RMS, resultando em 112.200 pares de entrada e saída para cada RNA.

Para a aplicação das RNAs, conforme mencionado anteriormente, foram utilizadas redes do tipo PMC contendo 6 valores de entrada, 20 neurônios na primeira camada escondida, 20 neurônios na segunda camada escondida e 1 neurônio de saída (6-20-20-1).

Através da utilização das RNAs são estimados os valores das tensões trifásicas em seis diferentes pontos de monitoramento. Entretanto, a RNA selecionada possui somente um neurônio na camada de saída, sendo necessário utilizar três RNAs para a estimação das tensões trifásicas de um ponto de monitoramento. Dessa forma, foram implantadas 18 RNAs com a topologia 6-20-20-1.

Cabe salientar que o principal objetivo desta pesquisa consiste em verificar o desempenho das RNAs mediante aos diferentes perfis de carga. O banco de dados para o treinamento e validação das RNAs foi separado em três partes (carga leve, média e pesada), cada uma consistindo de 2.200 casos, totalizando os 6.600 casos simulados e descritos anteriormente. Além de verificar o desempenho das RNAs, o presente trabalho também tem como intuito encontrar índices de acerto satisfatórios. Para isso, foram definidos quatro métodos de abordagem para o problema:

- (i) Utilização das redes já treinadas por [12] e todo o banco de dados compilado no presente trabalho para a validação das RNAs;
- (ii) Utilização de 70% do banco de dados da carga média para o treinamento e o restante para a validação;

- (iii) Utilização de 70% do banco de dados da carga alta e 70% do banco de dados da carga baixa para o treinamento e o restante para a validação; e
- (iv) Utilização de 70% do banco de dados da carga alta, 70% da carga média e 70% da carga leve para o treinamento, e o restante para validação.

Para melhor visualização das quatro abordagens, todos os dados foram sumarizados na Tabela IV.

TABELA IV. MÉTODOS PARA A ABORDAGEM DO PROBLEMA

Método	Banco de dados utilizado	Carga Leve	Carga Média	Carga Pesada
	Treinamento	RNAs [12]	RNAs [12]	RNAs [12]
(i)	Treinamento	100% (2.200 casos)	100% (2.200 casos)	100% (2.200 casos)
	Validação	100% (2.200 casos)	100% (2.200 casos)	100% (2.200 casos)
(ii)	Treinamento	-	70% (1.540 casos)	-
	Validação	100% (2.200 casos)	30% (660 casos)	100% (2.200 casos)
(iii)	Treinamento	70% (1.540 casos)	-	70% (1.540 casos)
	Validação	30% (660 casos)	100% (2.200 casos)	30% (660 casos)
(iv)	Treinamento	70% (1.540 casos)	70% (1.540 casos)	70% (1.540 casos)
	Validação	30% (660 casos)	30% (660 casos)	30% (660 casos)

Vale comentar que as abordagens (ii) e (iii) foram consideradas com o propósito fixo de observar a real capacidade de generalização das RNAs treinadas, visto que as informações apresentadas aos modelos não seriam totalmente representativas dos três perfis de cargas em análise.

Foram utilizados os mesmos parâmetros de treinamento para todas as abordagens citadas, consistindo em 800 épocas, algoritmo de treinamento do tipo *Levenberg Marquardt*, erro final desejado de 10^{-6} , função de ativação do tipo tangente hiperbólica para as duas camadas intermediárias e do tipo linear para a camada de saída. Vale ressaltar que foi realizado um total de 18 treinamentos para cada método apresentado na Tabela 1, pois são considerados 6 pontos de monitoramento, cada um com 3 RNAs para a obtenção da tensão trifásica.

VI. RESULTADOS E VALIDAÇÃO

Para os testes realizados através do método (i) foi possível constatar que o índice de acertos para os dados referentes à carga média, para a estimação das tensões trifásicas em todos os pontos de medição, permaneceu entre 50% e 80%, para erros abaixo de 0,07 p.u., inferiores aos resultados reportados em [12]. Esse fato pode ter sido ocasionado devido a uma mudança durante a fase da modelagem do SEP, onde o fator de potência adotado foi de 0,96, inferior aos trabalhos anteriores. Apesar do fator de potência ter sido levemente alterado, o valor das indutâncias declaradas no *software ATP* durante a fase da modelagem foi considerável, dado que o projeto aborda cargas industriais, todas com elevado valor de potência instalada. Essa mudança na modelagem pode ter gerado um banco de dados com padrões diferentes das quais as RNAs de [12] foram submetidas, possivelmente fora de

seu domínio de operação. Já o índice de acertos das cargas pesadas foi extremamente baixo, permanecendo entre 5% e 8%, com exceção da fase A do ponto de monitoramento 1 (Mn1), que apresentou taxa de acerto 47,64%. Esse fato evidencia a pouca abrangência do banco de dados, uma vez que as RNAs de [12] foram expostas somente ao caso de carga média.

Os métodos (ii) e (iii) apresentaram resultados insatisfatórios que não são pertinentes a este artigo. Estes métodos servem apenas para confirmar premissas anteriores de que o mapeamento dos dados não é linear. Ou seja, uma RNA não pode ser treinada apenas com dados referentes as cargas leve e pesada, e esperar-se que a situação de carga média seja generalizada de forma correta. O mesmo vale para o treinamento com dados referentes à carga média em relação à correta generalização para as cargas leve e pesada.

Das quatro abordagens apresentadas o procedimento (iv) se mostrou mais eficiente, conforme esperado. Neste sentido, será dado maior enfoque aos resultados provenientes desta abordagem.

O método (iv) submete as RNAs a um banco de dados contendo amostras dos três tipos de carga (leve, média e pesada). Para o conjunto este conjunto de dados, contemplando os três perfis de cargas, foram obtidos resultados mais satisfatórios quando comparados aos anteriores (i - iii).

Os resultados obtidos para o ponto de monitoramento 1 estão sumarizados nas Tabelas V, VI e VII.

TABELA V. ERRO DAS FASES A, B E C PARA O PONTO DE MONITORAMENTO 1 PARA A CARGA MÉDIA PARA O MÉTODO (IV).

Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
A	38,50	58,79	72,70	83,03
B	41,57	64,87	80,00	88,17
C	41,63	62,77	77,41	88,41

Para exemplificar, toma-se como exemplo a Tabela V. Para os 11 tipos diferentes de curto-circuito, com base nas 2200 situações avaliadas, 83,03 % das respostas apresentaram um erro na estimação das tensões trifásicas abaixo de 0,07 p.u. para a fase A. Ainda para esta fase, 38,5% dos casos analisados apresentaram um erro de estimação menor do que 0,01 p.u..

TABELA VI. ERRO DAS FASES A, B E C PARA O PONTO DE MONITORAMENTO 1 PARA A CARGA LEVE PARA O MÉTODO (IV).

Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
A	45,26	68,12	81,37	88,14
B	47,95	73,80	85,63	91,00
C	47,24	72,70	86,31	92,19

TABELA VII. ERRO DAS FASES A, B E C PARA O PONTO DE MONITORAMENTO 1 PARA A CARGA PESADA PARA O MÉTODO (IV).

Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
A	36,04	53,39	65,80	74,20
B	38,93	58,20	71,96	81,48
C	38,11	55,99	69,83	80,73

Os resultados para os demais pontos de monitoramento foram próximos aos apresentados nas Tabelas V - VII, permanecendo entre 70% e 80% para um erro menor do que 0,07 p.u.

Diante dos resultados deste último método, o qual expôs as RNAs aos dados pertencentes a todo o domínio do banco de dados, constata-se o aumento da complexidade do problema em questão, destacando a possibilidade de investigação do aumento do número de neurônios das camadas intermediárias para a obtenção de melhores resultados.

VI. CONCLUSÃO

Este projeto teve como principal objetivo mostrar e analisar o comportamento e os índices de acertos das RNAs frente às diferentes variações de carga ao qual o SEP teste foi submetido [14].

Para isso, foram modelados via o *software* ATP perfis de carga pesada, média e leve, os quais formaram o banco de dados utilizado na aplicação das RNAs. Como ponto de partida, analisou-se o comportamento das RNAs já treinadas em trabalhos anteriores [12] (método (i)), verificando-se nesta pesquisa um baixo índice de acertos para as cargas pesadas, possuindo valor mínimo de 0,37% de acertos para um erro menor do que 0,01 p.u. para o ponto de monitoramento 4 da fase A, e valor máximo de 47,64% de índice de acertos para um erro menor do que 0,07 p.u. para o ponto de monitoramento 1 da fase C. Dentro deste método, o melhor índice de acertos teve-se a situação de carga média, obtendo-se valor máximo de 80,07% para um erro menor do que 0,07 p.u. para o ponto de monitoramento 5 da fase B.

Os métodos (ii) e (iii) confirmam a dificuldade de generalização das RNAs quando não são expostas a um banco de dados de treinamento representativo. As simulações mostraram, de forma empírica, que o mapeamento realizado pelas RNAs é complexo e não linear, devendo ser cuidadosamente analisado de acordo com a complexidade do problema.

Por fim, o método (iv) de treinamento foi aplicado, onde foram utilizados dados referentes aos três perfis de carga, sendo 70% de cada um para o treinamento, e o restante para a fase de testes. Na presença desta configuração do banco de dados, as RNAs passaram a apresentar índices de acertos satisfatórios, permanecendo em torno de 90% para as cargas leves, 85% para as cargas médias, e 80% para as cargas pesadas, considerando um erro menor do que 0,07 p.u..

A diminuição do índice de acertos das RNAs, quando comparado ao que foi reportado em [12], pode ter sido ocasionada devido ao aumento da complexidade do problema quando inseridos diferentes perfis de carga.

Dessa forma, a melhoria da porcentagem de acertos deve ser investigada através do aumento do número de neurônios

das camadas intermediárias, por exemplo, uma vez que sua principal função consiste em imprimir não linearidades no entendimento e solução dos problemas apresentados à rede neural [16].

VII. REFERÊNCIAS

- [1] DUGAN, R. C.; M. F. McGranaghan, S. Santoso and H. W. Beaty, "Electrical Power Systems Quality", McGraw-Hill, 2nd Edition, ISBN: 0-07-138622-X, 2002.
- [2] BELISÁRIO, César D. A., Daniella A. Bahiense e Gecê M. Oliveira, "Continuidade nos Serviços de Distribuição de Energia Elétrica", Conj. & Planej., Salvador: SEI, n.105, p. 36-40, Fev 2003.
- [3] SINGH, Pushpendra; KOTHARI, D. P.; SINGH, Mool. Feasibility of Interconnected Distribution Network for the Integration of Distributed Energy Resources Using GA Approach. International Review of Electrical Engineering (IREE), v. 8, n. 1, p. 314-320, 2013.
- [4] BEZERRA, U. H. et al. Sistema para o Monitoramento da Qualidade de Energia Elétrica em Conjunto de Consumidores em Baixa Tensão. In: CITNEL – Congresso de Inovação Tecnológica em Energia Elétrica, Brasília – DF. 2001.
- [5] COLNAGO, Guilherme Piazentini. Desenvolvimento e implementação de um sistema de monitoramento em Tempo real da tensão da rede com acesso remoto. 2009. Tese de Doutorado. Universidade Federal do Espírito Santo.
- [6] ANEEL - Agência Nacional de Energia Elétrica, PRODIST – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional, Resolução Normativa nº395/2009 – Módulo 8 0 Rev.1
- [7] AGGARWAL, Raj; SONG, Yonghua. Artificial neural networks in power systems. III. Examples of applications in power systems. Power Engineering Journal, v. 12, n. 6, p. 279-287, 1998.
- [8] POPOVIĆ, D.; KUKOLJ, Dragan; KULIĆ, F. Monitoring and assessment of voltage stability margins using artificial neural networks with a reduced input set. IEE Proceedings-Generation, Transmission and Distribution, v. 145, n. 4, p. 355-362, 1998.
- [9] Leuven EMTP Center (1987). Alternative Transients Program Rule Book.
- [10] BOTTURA, F. B. et al. Redes neurais artificiais aplicadas ao monitoramento remoto dos níveis de tensão em um sistema de distribuição. In: X SBAI – Simpósio Brasileiro de Automação Inteligente, São João Del Rei – MG, 2011.
- [11] BOTTURA, F. B.; DE CAMARGO, F. S. P.; OLESKOVICZ, M. e DOS SANTOS, R. C. "Monitoramento remoto do perfil da tensão eficaz em cargas dispostas em um sistema de distribuição utilizando redes neurais artificiais". X Conferência Brasileira sobre Qualidade da Energia Elétrica (X CBQEE), Araxá, MG, Brasil, ISSN: 2236-8531, Anais (CD), 2013.
- [12] LIMA, D. F.; BOTTURA, F. B. e OLESKOVICZ, M. "Redes PMC aplicadas ao monitoramento remoto da tensão trifásica frente às situações de curtos-circuitos em um sistema de distribuição". XI Conferência Brasileira sobre Qualidade da Energia Elétrica (XI CBQEE), Campina Grande, PB, Brasil, Anais (CD), 2015.
- [13] BRASIL, Ministério das Minas e Energia, DNAEE, Eletrobrás, Empresas Concessionárias de Energia Elétrica; Nova Tarifa de Energia Elétrica: metodologia e aplicação, Brasília: DNAEE, 1985.
- [14] FRANCISQUINI, Aislán Antonio. Estimación de Curvas de Carga em Pontos de Consumo e em Transformadores de Distribuição, p. 11, 2006. Tese de Doutorado. Universidade Estadual Paulista "Júlio de Mesquita Filho".
- [15] Manual de Equipamentos Elétricos, 3ª edição, Rio de Janeiro, RJ, Editora LTC, 2005.
- [16] HAYKIN, Simon S. et al. Neural networks and learning machines. Upper Saddle River, NJ, USA: Pearson, 2009.