

Estimated Time to Failure of Distribution Power Transformers Using Data from the Operation Center and Artificial Neural Network (ANN)

Bruno R. Sodré*, Guilherme G. Sotelo*, Vitor H. Ferreira*

* Fluminense Federal University, PPGEET, Engineering School, Niteroi, RJ 22790-340, Brazil, (e-mail: bruno.sodre@light.com.br, gsotelo@id.uff.br, vhferrera@id.uff.br).

Abstract: Power transformers are increasingly demanded, given the increasing need to maintain the continuous supply of electricity by energy distribution companies. Power interruptions, due to the failure of this equipment, can generate financial compensations in the order of hundreds of thousands of reais for the companies, thus becoming ever more important to monitor the failure time of this equipment. Most of papers related to the failure diagnosis of power transformers uses as an input data, the analysis of dissolved gases in real time, however for small transformers, the cost of implementing this information may have the cost of the equipment. Therefore, this work proposes the use of conventional data monitored in any distribution control center in the world, such as: load cycle and short circuit events (SC), with the objective of performing fault prediction, through the modeling of an artificial neural network (ANN), which was trained, validated and tested, from real data of operation of a transformer that operated for 945 days.

Resumo: Transformadores de potência são cada vez mais exigidos, visto a necessidade cada vez maior de se manter o fornecimento contínuo de energia elétrica por parte das distribuidoras de energia. Interrupções de energia, por conta da falha desses equipamentos podem gerar compensações financeiras da ordem de centenas de milhares de reais para as distribuidoras, desta forma se tornando cada vez mais importante o monitoramento do tempo de falha desses equipamentos. Grande parte dos trabalhos relacionados ao diagnóstico de falhas em transformadores de potência, utilizam como dado de entrada a análise de gases dissolvidos em tempo real, porém para transformadores de pequeno porte, o custo para implementação dessa informação pode ter o custo do equipamento. Assim, este trabalho propõe a utilização de dados convencionais monitorados em qualquer centro de controle do mundo, como: ciclo de carregamento e eventos de curto-circuito (CC), com o objetivo de realizar a previsão de falhas, através da modelagem de uma rede neural artificial (RNA), que foi treinada, validada e testada, a partir de dados reais de operação de um transformador que operou durante 945 dias.

Keywords: Power transformers, computational methods, risk analysis, neural artificial network

Palavras-chaves: Transformadores de potência, métodos computacionais, análise de risco, redes neurais artificiais

1. INTRODUÇÃO

A necessidade de suprimento contínuo de energia elétrica é uma realidade mundial, de modo que a infraestrutura necessária para garantir esse suprimento tem se tornado um desafio para os seguimentos de operação e manutenção, os quais muitas vezes admitem condições severas de operação dos equipamentos da rede. O transformador é um dos equipamentos mais importantes nos sistemas de distribuição e transmissão, porém está suscetível a diferentes tipos de falhas, que podem ocasionar interrupções no fornecimento de energia.

Conforme descrito em (C.Bengtsson, 1996), a avaliação da vida útil remanescente dos transformadores é uma das questões mais importantes relacionadas ao monitoramento e

diagnóstico, dos mesmos, tendo em vista que a falha desse equipamento pode ter como consequência, para os clientes atendidos pelo mesmo, uma interrupção de longa duração; adicionalmente o impacto para a distribuidora está relacionado a degradação dos índices de qualidade de fornecimento definidos pela agência nacional de energia elétrica (ANEEL), como por exemplo DEC (Duração equivalente de interrupção por unidade consumidora), FEC (Frequência equivalente de interrupção por unidade consumidora) e compensações financeiras decorrentes das violações individuais dos indicadores de qualidade, os quais são estabelecidos nos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), módulo 08 (ANEEL, 2018). A definição de monitoramento, está relacionada a coleta de dados, que em um cenário ideal ocorre em tempo real, desenvolvimento de sensores, técnicas de medição para

aplicações on-line e aquisição de dados, que estão relacionadas a parâmetros de grande importância para o transformador como: operação dos comutadores em carga, descargas parciais e temperatura do topo do óleo. Já a definição de diagnóstico, contempla a interpretação do conjunto de dados obtidos a partir do sistema de monitoramento, o qual deve ser capaz de sugerir ações para o operador, de modo que o centro de controle consiga realizar o planejamento da operação deste ativo, como por exemplo uma substituição preventiva, a partir das informações enviadas do equipamento para o centro de controle.

Os trabalhos presentes na literatura que abordam previsões de falhas em transformadores, por meio da utilização de métodos baseados em inteligência artificial (IA), utilizam em sua grande maioria, como dados de entrada, as concentrações em tempo real de gases dissolvidos no óleo, as quais dependem de sensores específicos para essa aquisição. Na seção 2 será abordada a revisão bibliográfica de trabalhos, que utilizam esses dados como entrada para a realização das previsões. Contudo, em transformadores de pequeno porte, como os do escopo deste trabalho, o custo destes sensores, quando comparado ao valor desses transformadores, acaba se tornando impeditivo tendo em vista que este monitoramento pode ter o custo do equipamento.

Assim, esse trabalho traz como contribuição uma proposta de modelo, baseado em redes neurais artificiais (RNAs), cujo objetivo é prever o tempo de falha em transformadores de potência de pequeno porte (3 MVA – 25 kV/13,8 kV), através de grandezas que convencionalmente não são utilizadas na literatura para este tipo de previsão, porém estão disponíveis em qualquer centro de controle do mundo, como: ciclo de carregamento e eventos de curto-circuito (CC). A previsão de falhas para os transformadores do escopo deste trabalho, é uma importante ferramenta de direcionamento de manutenções preditivas, com o objetivo de mitigar possíveis falhas e consequentemente interrupções do fornecimento de energia. Em (Farag, Mohandes and Al-shaikh, 2001) é apresentado uma proposta de modelo de previsão de falhas em transformadores, baseada em IA, que também não utiliza grandezas convencionalmente utilizadas para esse tipo de previsão, o qual necessita de aprimoramentos, tendo em vista que a saída esperada não é conclusiva em relação ao tempo para a falha do equipamento. Desta forma, este trabalho explora uma lacuna na literatura referente a previsão de falhas, utilizando grandezas não convencionais, com o intuito de obter uma saída objetiva: o tempo para a falha do equipamento.

Este trabalho está apresentado por esta seção introdutória, a seção 2 trata dos métodos de diagnósticos de falhas em transformadores de potência, a seção 3 apresenta a descrição dos indicadores de qualidade de fornecimento regulamentados pela ANEEL, a seção 4 trata da metodologia utilizada para a modelagem da rede neural, a seção 5 trata da validação do modelo, a seção 6 apresenta cenários de simulações utilizando o modelo implementado e a seção 7 apresenta a conclusão deste trabalho.

2. MÉTODOS DE DIAGNÓSTICOS DE FALHAS EM TRANSFORMADORES DE POTÊNCIA

Conforme (C.Bengtsson, 1996; Kovacevic and Dominelli, 2003) (Wang, 2000) os métodos de diagnósticos podem ser agrupados em três conjuntos classificados por tipo de falha: i) Falhas Térmicas. Estes tipos de falhas podem ser analisadas através do método DGA (Dissolved Gas Analysis), que considera a concentração dos gases dissolvidos no óleo, da temperatura, e da medida do grau de polimerização, que quantifica a degradação da celulose. ii) Falhas Relacionadas ao Dielétrico. A caracterização e localização das descargas parciais é o principal método empregado para detectar falhas relacionadas à falhas no dielétrico. iii) Falhas Mecânicas. Estas falhas geralmente são resultado de forças provocadas por CC ou por vibrações dos enrolamentos e núcleo. O resultado destas falhas são as deformações dos enrolamentos e partes mecânicas internas do transformador.

2.1. Falhas térmicas

Transformadores em constante operação, podem estar sujeitos a condições térmicas e elétricas, acima dos limites especificados pelo fabricante. Estresses excessivos resultarão na degradação do isolante elétrico, culminando na formação de gases provenientes destas condições de operação, tais como: hidrogênio (H₂), metano (CH₄), acetileno (C₂H₂), etileno (C₂H₄), etano (C₂H₆), monóxido de carbono (CO) e dióxido de carbono (CO₂) (Zakaria, Johari and Musirin, 2012).

Existem várias técnicas de análise de gases dissolvidos, como por exemplo as normas IEE (Kelly, 1980), IEC 60599 (Peimankar *et al.*, 2017), bem como os métodos de Roger e Doernenburg (Hairu, Li; Daowu, Yang; Zhou, Ren; Zhewen, 2010). Esses métodos não envolvem nenhum tipo de formulação matemática, onde as interpretações dos resultados são realizadas basicamente através da experiência/conhecimento de diagnósticos de falta anteriores (Meng *et al.*, 2010). De modo a contornar essa limitação, métodos computacionais baseados em IA são utilizados para a previsão de faltas, como por exemplo RNAs (Zhang *et al.*, 1996), sistemas inteligentes (SI) (Lin, C. E.; Ling, J. M.; Huang, 1993) e lógica Fuzzy (LF) (Tomsovic, Tapper and Ingvarsson, 1993). Em (Lima, Saavedra and Miranda, 2015) é proposto um modelo determinístico visando estimar a probabilidade de falhas em transformadores de potência, considerando sua perda de vida útil, devido ao seu ciclo de carregamento, bem como a análise em tempo real dos gases dissolvidos no óleo, com o objetivo de auxiliar o planejamento da operação deste ativo. A modelagem da perda de vida útil (%PV) é determinada a partir da equação (1), que é baseada na teoria de Arrhenius, considerando o ponto mais quente como referência:

$$PV\% = 10^{-\left(\frac{B}{273 + \theta_{en}}\right)} \cdot \Delta t_i \cdot 100 \quad (1)$$

Onde PV% representa a perda percentual de vida útil do transformador, Δt_i é o tempo de operação em horas, θ_{en} é a temperatura do ponto mais quente em Kelvin, A e B são parâmetros definidos nas normas IEEE C57.91-1995 (IEEE Standards Association, 2012) e NBR 5416 (ABNT, 1997), onde $B=6.972,15$ e $A=14,1333$ (transformadores com elevação de temperatura de 55 °C)

2.2. Falhas relacionadas ao dielétrico

Falhas relacionadas ao dielétrico estão relacionadas a descargas parciais, no isolamento principal, que geralmente representam uma grande ameaça para o funcionamento do transformador. Para um diagnóstico correto depois de receber um sinal de alarme via sensores ou por amostragem dos gases dissolvidos no óleo, é necessário localizar e caracterizar a fonte da descarga parcial, a qual é realizada através de um analisador de descargas parciais (C.Bengtsson, 1996). No entanto, em alguns casos estes sistemas, não intrusivos, podem ser ineficientes por estarem sujeitos a interferências de ruído proveniente do meio externo ao transformador. Este problema, entretanto, vem sendo superado através da implementação de técnicas de processamento digital de sinais para identificar o espectro de frequência das descargas parciais, isolando-o do ruído ambiente.

2.3. Falhas Mecânicas

Falhas de origem mecânica na parte ativa do transformador são frequentemente resultado de forças de CC, ou de possíveis vibrações de partes de suporte dos enrolamentos ou do núcleo. Este diagnóstico pode ser realizado através do teste de análise de resposta em frequência (SFRA), que realiza a medição da função de transferência do transformador, onde as deformações nos enrolamentos principais podem ser detectadas, a partir de uma medição de referência. (C.Bengtsson, 1996)

Conforme proposto em (Patil and Chaudhari, 2012), o diagnóstico de falhas em transformadores é realizado através da análise combinada dos gases dissolvidos no óleo e de testes elétricos para a identificação de falhas mecânicas, SFRA. São propostos dois estudos de caso baseados em transformadores sobreaquecidos, onde o modelo proposto tem como objetivo ajudar a identificar a área afetada, bem como a causa do superaquecimento antes da falha do transformador.

3. INDICADORES DE QUALIDADE DO FORNECIMENTO

A falha em transformadores de potência pode representar impactos relevantes nos indicadores de qualidade de

forneimento das distribuidoras, onde conforme regulamenta a ANEEL, as ocorrências com tempo superior a três minutos, são classificadas como ocorrências de longa duração, conforme definido no PRODIST módulo 08 (ANEEL, 2018). A continuidade do fornecimento é avaliada pela ANEEL através de subdivisões das distribuidoras, denominadas conjuntos elétricos, os quais possuem limites para os indicadores associados a cada conjunto, que podem ser consultados em (ANEEL, 2019). Ressalta-se que o conjunto elétrico pode ter abrangência variada, onde conjuntos grandes podem abranger mais de um município, ao mesmo tempo que alguns municípios podem possuir mais de um conjunto.

Os limites dos indicadores DIC (Duração de interrupção individual por unidade consumidora) e FIC (Frequência de interrupção individual por unidade consumidora) são definidos para períodos mensais, trimestrais e anuais. O limite do indicador DMIC (Duração máxima de interrupção contínua por unidade consumidora ou ponto de conexão) é definido para períodos mensais. O limite do indicador DICRI (Duração da interrupção individual ocorrida em dia crítico por unidade consumidora ou ponto de conexão) é definido para cada interrupção em dia crítico.

Assim, os indicadores de qualidade são traduzidos em compensações financeiras, para cada unidade consumidora, conforme as equações 2,3,4, e 5.

Para o DIC:

$$Valor = \left(\frac{DICv}{DICp} - 1 \right) DICp * \frac{EUSDmédio}{730} * kei \quad (2)$$

Para o DMIC:

$$Valor = \left(\frac{DMICv}{DMICp} - 1 \right) DMICp * \frac{EUSDmédio}{730} * kei \quad (3)$$

Para o FIC:

$$Valor = \left(\frac{FICv}{FICp} - 1 \right) DICp * \frac{EUSDmédio}{730} * kei \quad (4)$$

Para o DICRI:

$$Valor = \left(\frac{DICRIv}{DICRIp} - 1 \right) DICRIp * \frac{EUSDmédio}{730} * kei \quad (5)$$

Onde:

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

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

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

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

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

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

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

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

EUSDmédio = média aritmética dos encargos de uso do sistema de distribuição correspondentes aos meses do período de apuração do indicador; 730 = número médio de horas no mês;

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

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

4. METODOLOGIA

O modelo proposto considera como dados de entrada basicamente duas grandezas: tempo em sobrecarga, que apresenta como consequência a redução do percentual de vida útil do transformador devido a seu ciclo de carregamento, bem como os eventos de CC externos ocorridos no alimentador associado a esse transformador. Desta forma, a modelagem da rede neural foi desenvolvida em Python, que teve como dados de entrada as grandezas mencionadas, as quais representam dados reais de um transformador de potência de pequeno porte (3 MVA – 25 kV/13,8 kV), pertencente a uma distribuidora do Rio de Janeiro. A ferramenta de cálculo utilizada para gerar as figuras foi o software Microsoft Excel, que utilizou os dados oriundos do programa desenvolvido.

Em relação a arquitetura da RNA, foi utilizada uma rede do tipo feedforward, de múltiplas camadas, uma camada

escondida, com treinamento supervisionado baseado no algoritmo de aprendizagem do tipo: retropropagação do erro (backpropagation). Foram realizadas simulações para a determinação da quantidade ótima de neurônios na camada escondida, bem como a seleção das entradas que tivessem melhor desempenho, através de quatro cenários, os quais serão detalhados na seção 5. A função de ativação escolhida na camada escondida e na saída, foi a função sigmoid, a qual não foi alterada nos processos iterativos.

4.1. Perda de Vida Útil, devido ao ciclo de carregamento do transformador

Conforme (Filho, 2005; Lima, Saavedra and Miranda, 2015), a vida útil do transformador está diretamente ligada ao carregamento que este é submetido ao longo do seu período de operação. Conforme definido na norma IEEE C57.91-1995 o óleo isolante do transformador se deteriora, como uma função do tempo e da temperatura, e como as temperaturas nos transformadores não são uniformemente distribuídas é comum utilizar a temperatura do ponto mais quente, dessa forma o cálculo do percentual de redução da vida útil (%PV) foi determinado a partir da equação (1).

Assim, para o treinamento do modelo, foi utilizado como exemplo um transformador que operou durante 945 dias, desta forma foi aquisitado o seu perfil de carregamento, em intervalos de tempo de 15 minutos, logo foi possível determinar o percentual diário de redução de sua vida útil, a partir da consideração citada em (Filho, 2005), que define que a temperatura do ponto mais quente é proporcional ao carregamento em tempo real do transformador, bem como determinar faixas de sobrecarga que o mesmo operou. Portanto, foram consideradas as seguintes entradas possíveis para o modelo: percentuais de perda de vida útil diários e acumulados, tempo que o transformador operou em sobrecarga segmentadas em quatro faixas, a partir de 100% até 130%, com intervalos de 10% entre cada faixa. As Figuras 1 e 2, apresentam, respectivamente, a perda de vida útil do transformador devido ao ciclo de carregamento e o tempo de operação em sobrecarga nas faixas mencionadas.

4.2. Eventos de CC

Assim como o carregamento em tempo real, os eventos de CC, com a determinação da magnitude do valor eficaz das correntes de CC, é uma informação comum disponível nos centros de controle. Desta forma, para a entrada do modelo foram consideradas as seguintes entradas possíveis: soma das correntes de CC máximas, quantidade de eventos de CC, quantidade de eventos de CC em até 3 minutos, quantidade de eventos de CC em até 30 minutos, quantidade de eventos de CC em até 300 minutos, onde cada variável é contabilizada de forma diária e acumulada, conforme mostrado na figura 3.

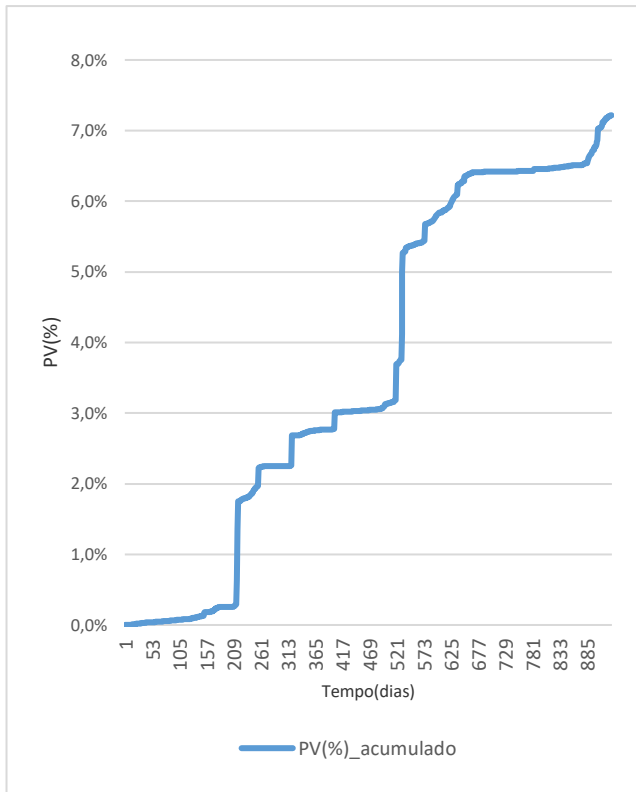


Fig. 1 Evolução da redução do percentual de vida útil, devido ao ciclo de carregamento do transformador.

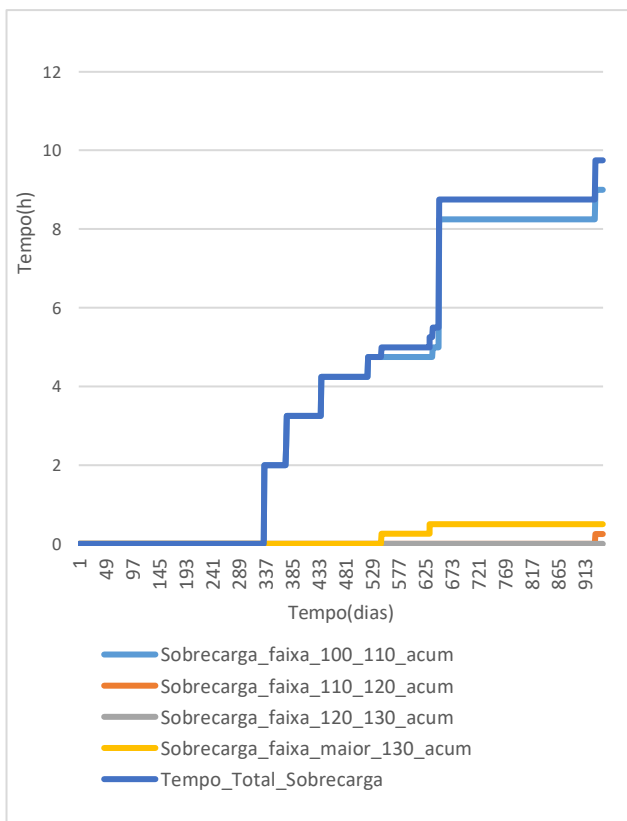


Fig. 2 Tempo de operação em sobrecarga do transformador.




Fig. 3 Evolução dos eventos de CC no transformador.

5. VALIDAÇÃO DO MODELO

Os dados de entrada para o treinamento, teste e validação do modelo, foram obtidos a partir das variáveis descritas nas seções 4.1 e 4.2, a partir de 945 exemplos, representados pelo tempo de operação do transformador, assim cada exemplo representa um dia de operação. A saída desejada, iniciada em 945 dias no primeiro exemplo, foi linearmente reduzida em um dia a cada exemplo. As bases para o treinamento, validação e testes, foram selecionadas de forma intercalada entre cada exemplo, assim, a base para o treinamento, por exemplo, recebeu os seguintes exemplos: primeiro, quarto, sétimo e assim por diante. Nas bases de teste e validação, foi aplicada a mesma estratégia, de forma que, cada base recebeu 33,33% dos dados disponíveis.

A partir da combinação das variáveis descritas nas seções 4.1 e 4.2, foi possível determinar quatro cenários, com o objetivo de verificar qual iria representar a melhor resposta para o modelo em questão. A

Tabela 1, apresenta as variáveis de entrada para cada cenário. As simulações foram realizadas para os cenários descritos, onde foram variados os neurônios da camada escondida para cada cenário. Foi utilizado como parâmetro de desempenho do modelo, o erro médio percentual, bem como o erro médio em dias. A função de ativação sigmoid foi utilizada tanto na camada escondida como na camada de saída, durante todos os processos iterativos e nos quatro cenários apresentados.

Nas etapas de treinamento e validação, foram realizadas até 4.000 épocas, com a utilização da função early stopping, que tem como objetivo terminar o treinamento, caso o erro de validação seja maior que o erro do treinamento. Os resultados das simulações são apresentados na figura 4, onde as entradas definidas no cenário 4, foram as que tiveram o melhor desempenho. A Tabela 2, Figuras 5 e 6, apresentam, respectivamente, as configurações do modelo que obtiveram os melhores resultados e as distribuições de frequências do erro em dias, para essas configurações.

Tabela 1 - Variáveis de entrada utilizadas nos cenários simulados

Cenário 1	Cenário 2	Cenário 3	Cenário 4
% perda vida útil diária e acumulada	% perda vida útil acumulada	Tempo em sobrecarga na faixa de 100% até 110%, diária e acumulada	Tempo em sobrecarga na faixa de 100% até 110%, acumulada
Soma das correntes de CC máximas diárias e acumuladas	Soma das correntes de CC máximas acumuladas	Tempo em sobrecarga na faixa de 110% até 120%, diária e acumulada	Tempo em sobrecarga na faixa de 110% até 120%, acumulada
Quantidade de CC diários e acumulados	Quantidade de CC acumulados	Tempo em sobrecarga na faixa de 120% até 130%, diária e acumulada	Tempo em sobrecarga na faixa de 120% até 130%, acumulada
Quantidade de CC em até 3 min diários e acumulados	Quantidade de CC em até 3 min acumulados	Tempo em sobrecarga na faixa de maior que 130%, diária e acumulada	Tempo em sobrecarga na faixa de maior que 130%, acumulada
Quantidade de CC em até 30 min diários e acumulados	Quantidade de CC em até 30 min acumulados	Soma das correntes de CC máximas diárias e acumuladas	Soma das correntes de CC máximas acumuladas
Quantidade de CC em até 300 min diários e acumulados	Quantidade de CC em até 300 min acumulados	Quantidade de CC diários e acumulados	Quantidade de CC acumulados
		Quantidade de CC em até 3 min diários e acumulados	Quantidade de CC em até 3 min acumulados
		Quantidade de CC em até 30 min diários e acumulados	Quantidade de CC em até 30 min acumulados
		Quantidade de CC em até 300 min diários e acumulados	Quantidade de CC em até 300 min acumulados

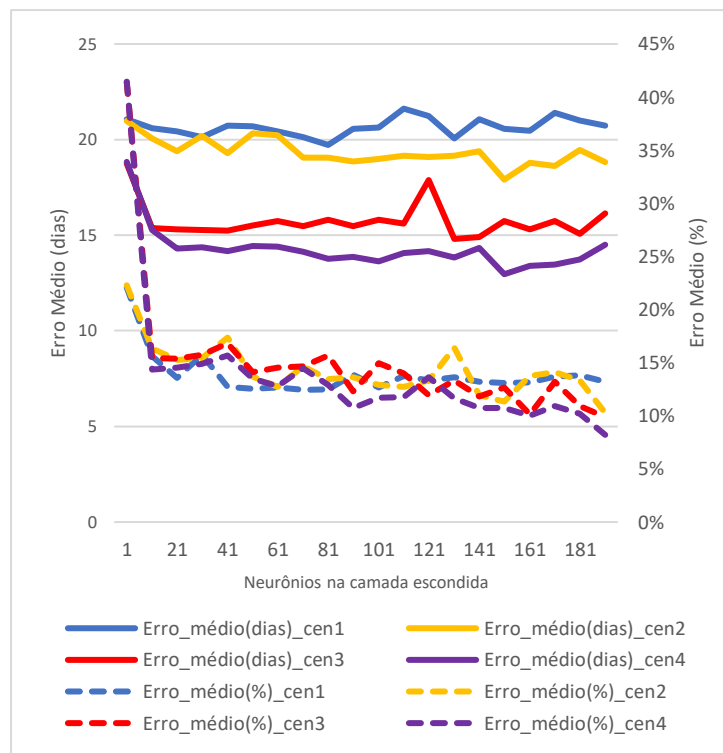


Fig. 4 Resultado das simulações, considerando os 4 cenários definidos na tabela 1.

Tabela 2 - Configurações que obtiveram melhor resultado nas simulações.

Cenário	Neurônios na camada escondida	Erro_médio (%)	Erro_médio (dias)
4	151	10,74%	12,96
4	191	8,21%	14,49




Fig. 5 Distribuição de frequências dos erros em dias para a configuração com 151 neurônios na camada escondida, no cenário 4.

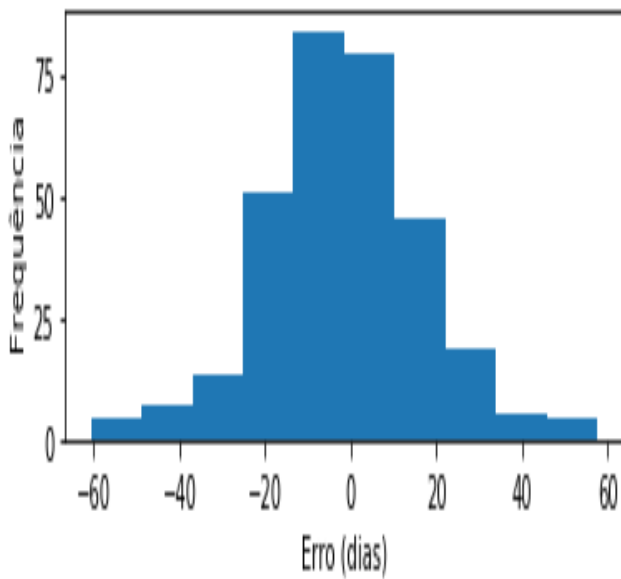


Fig. 6 Distribuição de frequências dos erros em dias para a configuração com 191 neurônios na camada escondida, no cenário 4.

6. ESTUDOS DE CASO

Através da validação do modelo descrito na seção anterior, foi realizada uma análise de sensibilidade das entradas utilizadas pelo modelo, onde foi considerado o aumento das quantidades de CC, bem como os valores máximos de corrente de CC em três patamares 10%, 30% e 50%, devido a um cenário hipotético da expansão da rede de distribuição, considerando que esta expansão, torna mais provável o aumento dos eventos de CC que impactam no transformador. As simulações foram realizadas utilizando os dados de entrada do cenário 4, com 191 neurônios na camada escondida. Desta forma, as Figuras 7, 8 e 9, apresentam os resultados das simulações realizadas. Fica evidente, através das figuras citadas anteriormente, o impacto do aumento das variáveis selecionadas na vida útil do transformador, desta forma a modelagem proposta se torna importante, no sentido da tomada de decisão por parte do planejamento da operação, de proceder uma inspeção de modo a localizar as possíveis causas dos eventos de CC, que em muitas vezes são provocadas pela vegetação em contato com a rede.

A solução de curto prazo mais provável estará fundamentada, por exemplo, na realização de podas ao longo do alimentador, que terá o custo de algumas dezenas de milhares de reais, ao passo que a perda do transformador, pode gerar o impacto de algumas centenas de milhares de reais, por conta de violações dos indicadores de qualidade mencionados na seção 3, bem como o impacto do índice de satisfação dos clientes envolvidos.

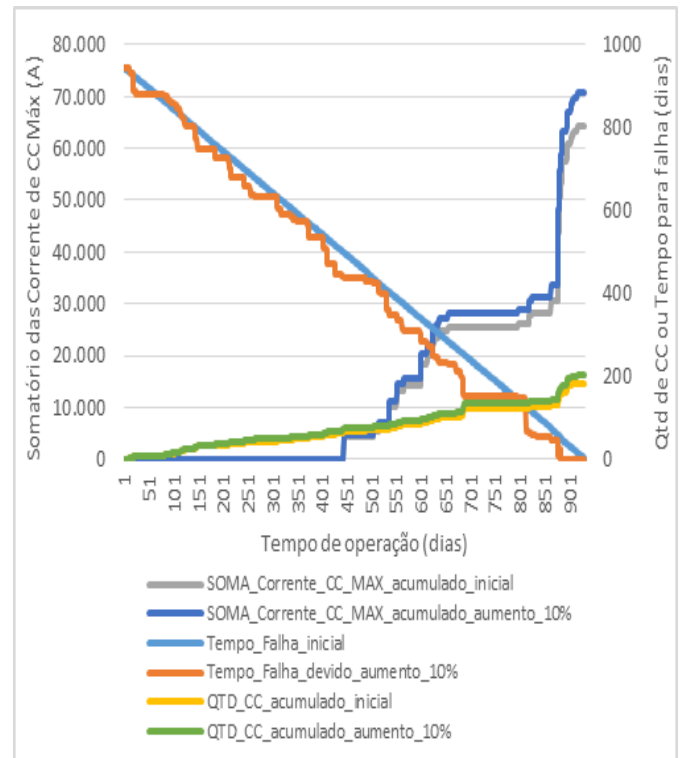


Fig. 7 Simulações considerando aumentos diários de 10 %, das variáveis de entrada: soma das correntes de CC máximas e quantidade de eventos de CC.

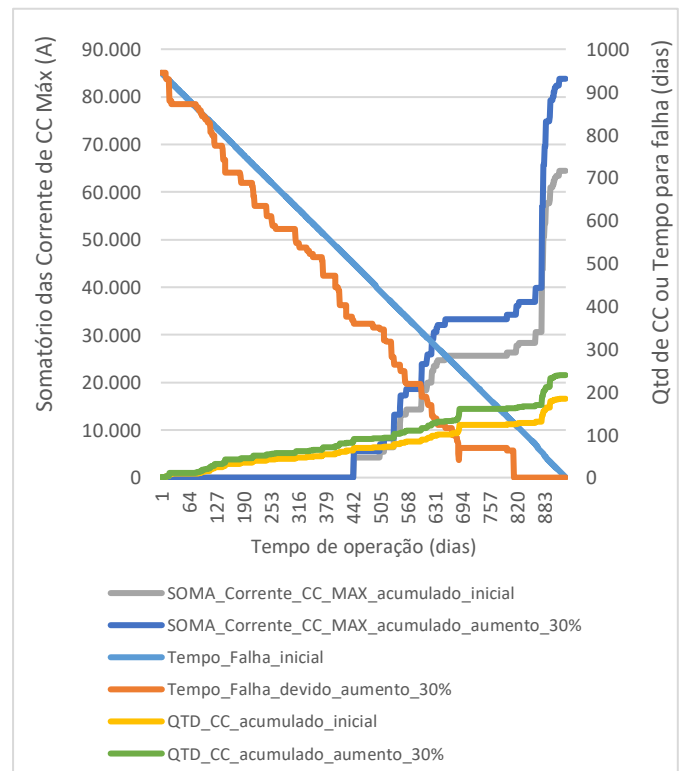


Fig. 8 Simulações considerando aumentos diários de 30 % das variáveis de entrada: soma das correntes de CC máximas e quantidade de eventos de CC.

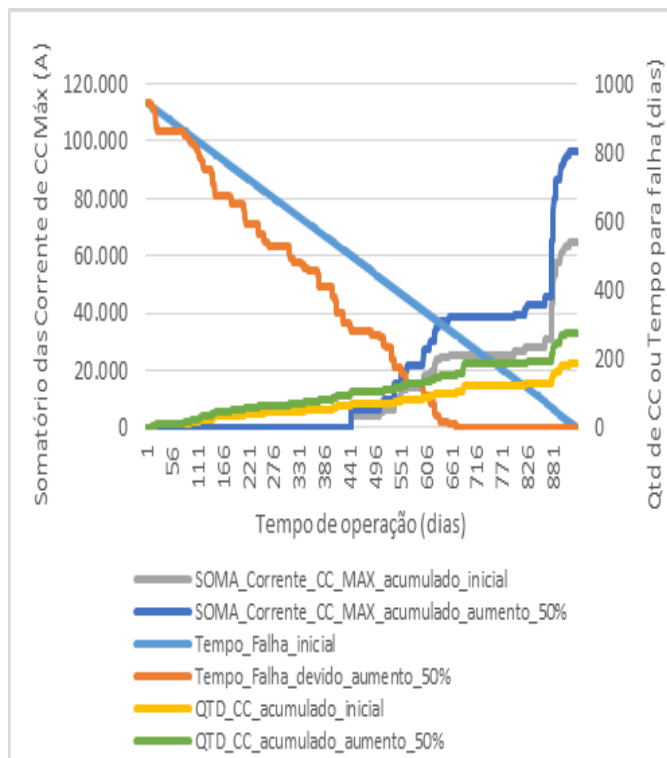


Fig. 9 Simulações considerando aumentos diários de 50 % das variáveis de entrada: soma das correntes de CC máximas e quantidade de eventos de CC.

7. CONCLUSÃO

Este trabalho apresentou uma proposta de modelagem, do tempo de falha em transformadores de potência de pequeno porte, através de grandezas convencionais monitoradas em qualquer centro de controle do mundo, como: ciclo de carregamento e eventos de CC.

A metodologia utilizada foi baseada em uma rede neural, do tipo feedforward, de múltiplas camadas, com uma camada escondida, onde foram simulados quatro cenários com variáveis de entrada distintas, sendo que para cada cenário, foi determinada a quantidade ótima de neurônios na camada escondida.

Considerando a etapa de validação do modelo, foram simulados três cenários, com o objetivo de apresentar uma análise de sensibilidade do modelo, aumentando em 10%, 30% e 50% as seguintes variáveis de entrada: quantidades de CC e valores máximos da corrente de CC, que como esperado, tiveram como consequência a redução do tempo de vida útil do transformador.

Como possíveis trabalhos futuros, pode-se apontar, ampliar a abrangência modelo, considerando mais transformadores, para a validação da rede neural.

8. REFERÊNCIAS

ABNT (1997) ‘Aplicação de Cargas em Transformadores de Potência’, *NBR 5416*.

ANEEL (2018) ‘Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST - Módulo 8 - Qualidade da Energia Elétrica - Rev. 10’, 10, p. 88.

ANEEL (2019) *Divulgação dos limites dos indicadores DIC, FIC, DMIC e DICRI, Rio de Janeiro*.

C.Bengtsson (1996) ‘Status and Trends in Transformer Monitoring’, *IEEE Transactions on Power Delivery*, 11(3), pp. 1379–1384.

Farag, A. S., Mohandes, M. and Al-shaikh, A. (2001) ‘Diagnosing failed distribution transformers using neural networks’, 16(4), pp. 631–636.

Filho, J. M. (2005) ‘Manual de Equipamentos Elétricos’, *LTC*, 3 ed(Rio Janeiro).

Hairu, Li; Daowu, Yang; Zhou, Ren; Zhewen, L. (2010) ‘Based on PSO-BP network algorithm for fault diagnosis of power transformer’, *Computer, Mechatronics, Control and Electronic Engineering (CMCE)*, 4(2010 International Conference on), pp. 484–487.

IEEE Standards Association (2012) *IEEE Guide for Loading Mineral- Oil-Immersed Transformers and Step-Voltage Regulators*. doi: 10.1109/IEEESTD.2012.6166928.

Kelly, J. J. (1980) ‘Transformer fault diagnosis by dissolved-gas analysis’, *IEEE Trans. Ind. Appl.*, IA-16, pp. 777–782.

Kovacevic, S. and Dominelli, N. (2003) ‘Transformer Life Extension by Continuous On-Line Oil Conditioning’, *Electrical Insulation Conference and Electrical Manufacturing and Coil Winding Conference and Exhibition*, pp. 271–275. doi: 10.1109/eicemc.2003.1247896.

Lima, S. L., Saavedra, O. R. and Miranda, V. (2015) ‘A two-level framework to fault diagnosis and decision making for power transformers’, *IEEE Transactions on Power Delivery*. Institute of Electrical and Electronics Engineers Inc., 30(1), pp. 497–504. doi: 10.1109/TPWRD.2014.2355176.

Lin, C. E.;Ling, J. M.;Huang, C. L. (1993) ‘An expert system for transformer fault diagnosis using dissolved gas analysis’, *IEEE Transactions on Power Delivery*, 8, no, pp. 231–238.

Meng, K. *et al.* (2010) ‘A self-adaptive RBF neural network classifier for transformer fault analysis’, *IEEE Transactions on Power Systems*, 25(3), pp. 1350–1360. doi: 10.1109/TPWRS.2010.2040491.

Patil, S. S. and Chaudhari, S. E. (2012) ‘An attempt to investigate the transformer failure by using DGA and SFRA analysis’, *Proceedings of the IEEE International Conference on Properties and Applications of Dielectric Materials*, pp. 1–4. doi: 10.1109/ICPADM.2012.6318985.

Peimankar, A. *et al.* (2017) ‘Evolutionary multi-objective fault diagnosis of power transformers’, *Swarm and Evolutionary Computation*. Elsevier B.V., 36, pp. 62–75. doi:

10.1016/j.swevo.2017.03.005.

Tomsovic, K., Tapper, M. and Ingvarsson, T. (1993) 'A fuzzy information approach to integrating different transformer diagnostic methods', *IEEE Transactions on Power Delivery*, 8(3), pp. 1638–1646. doi: 10.1109/61.252690.

Wang, M. A. (2000) 'Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults', Z., Doctorat t(Blacksburg, Virginia).

Zakaria, F., Johari, D. and Musirin, I. (2012) 'Artificial neural network (ANN) application in dissolved gas analysis (DGA) methods for the detection of incipient faults in oil-filled power transformer', *Proceedings - 2012 IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2012*, pp. 328–332. doi: 10.1109/ICCSCE.2012.6487165.

Zhang, Y. *et al.* (1996) 'An Artificial Neural Network Approach to Transformer Fault Diagnosis', 11(4), pp. 1836–1841.