

Metodologia para Estimar a Vida Útil de Para-raios de Óxido de Zinco Baseada na Aplicação do Sistema Neuro-Fuzzy Adaptativo

Vandilson R. N. Barbosa*, Edson G. Costa*, George R. S. Lira*, Marianna B. B. Dias*, Iago B. Oliveira*, Alysson H. P. Oliveira*, Giovanni M. B. Galdino*, Matheus V. A. Nascimento*

*Departamento de Engenharia Elétrica, Universidade Federal de Campina Grande - UFCG, Campina Grande, Paraíba, Brasil, (e-mail: vandilson.barbosa@ee.ufcg.edu.br)

Abstract: This work presents a methodology to be used to estimate the Metal Oxide Surge Arresters' (MOSAs') useful life, based on the prediction model based on the Adaptive Neuro-Fuzzy Inference System (ANFIS). For this purpose, a database consisting of MOSA's total leakage current was used. Thus, it was possible to build a time series composed of values of the third harmonic component of the leakage current. This component is one of the indicators of the MOSAs' degradation level most used in the surge arresters monitoring. Subsequently, the forecasting models based on artificial intelligence (ANFIS and Support Vector Regression - SVR) were implemented, evaluated, and compared. During implementations, the ANFIS model was tested with three distinct membership functions: Gaussian, Generalized Bell-Shaped, and Pi-Shaped; and the SVR model was tested with three different kernel functions: Gaussian, Linear, and Polynomial. The performance of each implemented model was evaluated using the determination coefficient in the training phase of the models and the mean absolute percentage error, in the validation phase. Considering the results obtained by the ANFIS e SVR models, it was found that the forecasts made using the ANFIS model with Gaussian membership function were the most accurate forecasts. Thus, the proposed methodology, which applies the ANFIS model with Gaussian function, was used to estimate the MOSA's useful life.

Resumo: Este trabalho apresenta uma metodologia para ser utilizada na estimação da vida útil de para-raios de Óxido de Zinco (ZnO), utilizando um modelo de previsão baseado no Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS, do inglês *Adaptive Neuro-Fuzzy Inference System*). Para tanto, um banco de dados foi utilizado, o qual foi constituído por sinais da corrente de fuga total de para-raios. Assim, foi possível construir uma série temporal composta por valores da terceira componente harmônica da corrente de fuga. Essa componente é um dos indicadores do nível de degradação de para-raios mais empregados no monitoramento desses equipamentos. Em seguida, modelos de previsão baseados em inteligência artificial, os modelos ANFIS e Regressão por Vetores de Suporte (SVR, do inglês *Support Vector Regression*), foram implementados, avaliados e comparados, a fim de identificar o modelo que apresenta o melhor desempenho. Durante as implementações, o modelo ANFIS foi testado com três funções diferentes de pertinência: Gaussiana, Sino Generalizada e Pi; e o modelo SVR foi testado com três funções diferentes de *kernel*: Gaussiana, Linear e Polinomial. A avaliação do desempenho de cada um dos modelos implementados foi realizada mediante o emprego do coeficiente de determinação, na fase de treinamento, e a utilização do erro percentual absoluto médio, na fase de validação. Considerando os resultados obtidos pelos modelos ANFIS e SVR, constatou-se que as previsões realizadas por meio do modelo ANFIS com função de pertinência Gaussiana apresenta as previsões mais exatas. Dessa forma, a metodologia proposta, que aplica o modelo ANFIS com função Gaussiana, foi usada para estimar a vida útil de para-raios de ZnO.

Keywords: useful life estimation; artificial intelligence; forecasting models; time series; metal oxide surge arresters.

Palavras-chaves: estimativa da vida útil; inteligência artificial; modelos de previsão; séries temporais; para-raios de ZnO.

1. INTRODUÇÃO

Os para-raios de Óxido de Zinco (ZnO) são equipamentos utilizados na proteção do Sistema Elétrico de Potência (SEP) e são responsáveis por limitar as sobretensões de origem externa (descargas atmosféricas) ou interna (operações de manobra) a níveis suportáveis por outros equipamentos

elétricos das subestações, das linhas de transmissão e de distribuição (Hinrichsen, 2012).

Os para-raios de ZnO vêm sendo empregados há mais de quarenta anos e devido às suas características altamente não lineares têm aumentando a confiabilidade, economia e continuidade de operação dos sistemas elétricos (Sakshaug 1991; Hinrichsen 2012). Considerando o papel e importância dos para-raios para o sistema elétrico, torna-se

necessário o desenvolvimento de técnicas que permitam estimar ou avaliar (monitorar e diagnosticar) o estado operacional de para-raios.

Na literatura, há diversas técnicas de monitoramento e diagnóstico de para-raios de ZnO, que foram desenvolvidas com o objetivo de minimizar os transtornos causados pela falha de para-raios (Heinrich & Hinrichsen 2001; Lira et al. 2018). Os primeiros trabalhos focaram no estudo de indicadores do nível de degradação de para-raios, que pudessem ser utilizados no monitoramento (Shirakawa et al. 1988; Cofeen & McBride 1991; Hinrichsen 1997). Como várias pesquisas têm relatado a eficácia da componente resistiva da corrente de fuga, métodos foram desenvolvidos para determinar essa componente (Heinrich & Hinrichsen 2001; Fu et al. 2017).

Na literatura há diversas técnicas de monitoramento e diagnóstico da degradação dos para-raios de ZnO, sendo a maioria delas baseadas na medição da temperatura e extração da corrente resistiva (IEC 60099-5 2013; Lima Júnior 2014; Lira et al. 2018; Dobrić & Žarković 2020). Outros estudos foram propostos a fim de desenvolver técnicas inteligentes de diagnóstico de para-raios, em que grande parte delas utilizam inteligência artificial para compor um classificador de estados, utilizando outros indicadores, tais como relações derivadas do conteúdo harmônica da corrente (Lira & Costa 2013; Khodsuz & Mirzaie 2015; Dobrić & Žarković 2020). Adicionalmente, trabalhos têm sido publicados relatando a eficácia da terceira componente harmônica da corrente para monitoramento e diagnóstico de para-raios, com foco na aplicação em campo (Shirakawa et al. 1988; Lima Júnior 2014; Metwally, Eladawy & Feilat 2017; Dobrić & Žarković 2020).

Apesar da grande quantidade de pesquisas desenvolvidas voltadas para monitoramento e diagnóstico de para-raios, a estimativa da vida útil de equipamentos elétricos tem sido mais relevante, em relação ao monitoramento e diagnóstico. A otimização do gerenciamento de ativos (para-raios, por exemplo) do sistema elétrico possibilita a determinação do momento ótimo para substituição do para-raios de campo (Wen & Zhou 2004; Liu et al. 2012; Dobrić & Žarković 2020; Muremi & Bokoro 2020). O correto gerenciamento do ativo pode otimizar recursos de manutenção e mitigar prejuízos financeiros provenientes das onerosas multas por indisponibilidade decorrente da necessidade de manutenção não programada.

A estimativa da vida útil de um para-raios pode ser realizada por meio da previsão de séries temporais, utilizando modelos estatísticos e de regressão, como também a partir de modelos baseados em inteligência artificial (Zhou et al. 2007; Liu et al. 2012). Caso a série possua comportamento não linear, com variações abruptas e seja não estacionária, os modelos baseados em inteligência artificial são os mais adequados, por possuírem, como principal característica, a excelente capacidade de adaptação, mesmo para um conjunto de dados com desempenho complexo (Haykin 2008; Suparta & Alhasa 2016).

Dentre os modelos baseados em inteligência artificial empregados para previsão de séries temporais, os modelos baseados em Sistema de Inferência Neuro-Fuzzy Adaptativo

(ANFIS, do inglês *Adaptive-Neuro-Based Fuzzy Inference System*) e Regressão por Vetores de Suporte (SVR, do inglês *Support Vector Regression*) vêm sendo largamente empregados. Estes modelos têm apresentado desempenho superior no processo de previsão, em relação aos demais tipos de inteligência artificial (Haykin 2008; Suparta & Alhasa 2016; Khan et al. 2019; Zaghloul et al. 2020).

A IEC 60099-5 (2013) indica a corrente de fuga (terceira componente harmônica e componente resistiva), a temperatura externa, a perda de potência e as descargas parciais como grandezas sensíveis ao nível de degradação de para-raios de ZnO. Quando se analisa defeitos nos varistores, a terceira componente harmônica da corrente de fuga se destaca (Heinrich & Hinrichsen 2001; Lira & Costa 2013). Ademais, a terceira componente harmônica pode ser obtida em campo sem a necessidade do sinal da tensão aplicada ao para-raios (IEC 60099-5 2013; Lima Júnior 2014).

O relatório da Tridelta (2002) e o trabalho proposto por Lima Júnior (2014) preconizam que o fim da vida útil do para-raios ocorre quando o valor de pico da terceira componente harmônica da sua corrente atinge 100 μ A. Embora esse valor seja apresentado por um fabricante de instrumentos de medição (pinça amperimétrica, por exemplo) e por um trabalho presente na literatura, o critério não deve ser considerado universal. Tendo em vista que o valor de pico da terceira componente harmônica da corrente de fuga pode ser usada como variável a ser observada e prevista (com o critério que indica o fim de vida útil dos para-raios), o emprego de modelos que realizam previsão de séries temporais pode ser aplicado.

Neste trabalho, apresentar-se-á uma metodologia que emprega um modelo de previsão baseado no ANFIS, para ser utilizada na estimação da vida útil de para-raios de ZnO. Para o desenvolvimento da metodologia, um banco de dados constituído por sinais da corrente de fuga total de para-raios será utilizado. Desse modo, a construção de uma série temporal composta por valores da terceira componente harmônica da corrente de fuga poderá ser realizada. Com isso, modelos de previsão baseados em inteligência artificial serão avaliados e comparados, para identificar o modelo que apresenta o melhor desempenho. Uma metodologia será proposta a partir do modelo que apresentar o melhor resultado.

2. BANCO DE DADOS

2.1 Medição em Campo

O banco de dados com sinais da corrente de fuga total de para-raios de ZnO foi construído a partir de medições realizadas em duas subestações distintas, ambas pertencentes a uma empresa brasileira de geração e transmissão de energia elétrica. Os sinais de corrente são oriundos de para-raios de ZnO envelhecidos naturalmente, tipo estação, do mesmo modelo e fabricante, com tempos de operação distintos. Ao todo foram utilizados oito para-raios. Os para-raios utilizados estavam instalados do lado de 69 kV de uma subestação 230/69 kV. Os dados técnicos dos para-raios avaliados são apresentados na Tabela 1.

Tabela 1. Dados técnicos dos para-raios

Tensão nominal	52,5 kV
Máxima tensão de operação contínua	42 kV
Tensão residual máxima	180 kV
Corrente nominal de descarga	20 kA
Classe de descarga	Classe 3
Varistor	ZnO
Invólucro	Porcelana

As medições, nas duas subestações, foram realizadas durante o ano de 2014. Durante esse ano, várias medições foram realizadas nos para-raios, em dias diversos, com intervalos de cinco a seis dias, durante um período de seis meses. Para as medições realizadas, também foram obtidos registros de tensão e temperatura ambiente, durante as medições. O valor médio da temperatura ambiente em que os para-raios estavam instalados era de 33,79 °C (com máximo de 36,00 °C e mínimo de 31,00 °C) e a tensão média, amplitude do sinal, durante as medições era de 70,17 kV (com máximo de 71,60 kV e mínimo de 69,13 kV), amplitude do sinal. Ao todo, 48 medições foram realizadas para cada uma dessas grandezas, além da aquisição do sinal de corrente de fuga total.

Como a campanha de medições teve como intuito criar um banco de dados com sinais da corrente de fuga total de para-raios com tempos de operação diferentes, que contemplasse condições de tempo de operação diversificado, para-raios com 8, 15 e 28 anos de operação foram selecionados. Na seleção foram escolhidos dois para-raios com 8 anos de operação, três para-raios com 15 anos e outros três com 28 anos.

Uma pinça amperimétrica com saída digital e um osciloscópio digital portátil com memória foram utilizados para a aquisição da corrente de fuga total nos para-raios. A pinça amperimétrica utilizada é composta por um transdutor magnético de corrente com núcleo bipartido, com resolução de 0,01 mA, precisão de saída de 5 dígitos, saída para visualização do sinal e faixa de frequência de 40 Hz a 2 kHz. O osciloscópio utilizado possui capacidade de registrar formas de onda com taxa de amostragem de 1 MSamples/s.

A extração da terceira componente harmônica foi realizada por meio da aplicação da Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*), que é um algoritmo largamente empregado por causa da sua eficiência (Gilat & Subramaniam 2012). Um novo banco de dados foi obtido utilizando a terceira componente harmônica da corrente de fuga total e os respectivos tempos de operação dos para-raios.

2.2 Tratamento Estatístico dos Dados

Considerando que o banco de dados não é composto por valores de pico da terceira componente harmônica da corrente de fuga obtidos por meio de medições sistemáticas, por exemplo: medições diárias ou mensais, tornou-se necessário determinar os valores de pico da terceira componente harmônica da corrente em vários estágios de degradação de para-raios de ZnO, no tempo.

Tabela 2. Estatística descritiva da terceira componente harmônica da corrente de fuga

Parâmetros estatísticos	8 anos	15 anos	28 anos
Média (μA)	8,58	9,59	16,10
Mediana (μA)	8,33	9,66	16,60
Desvio padrão (μA)	1,56	1,97	2,11
Mínimo (μA)	6,07	7,06	11,70
Máximo (μA)	10,70	14,07	19,60
Número de medições	12	18	18

Tendo em vista que os para-raios são do mesmo modelo e fabricante, isto é, características semelhantes, mas não iguais, aplicou-se a estatística descritiva para emular as variações (possibilidades) das condições operacionais dos para-raios em diversos momentos (tempos) de operação. As medições foram realizadas ao longo de um dia com condições de tensão aplicada e temperatura diferentes, durante seis meses, proporcionando obtenção de sinais da corrente de fuga diversificados. Além disso, a adoção de diferentes amostras de para-raios emula as variações oriundas do processo de fabricação e montagem dos para-raios.

Com o objetivo de levar em consideração as variações no modelo de previsão, a estatística descritiva desses valores foi realizada utilizando os valores da terceira componente harmônica extraídos dos sinais de corrente de fuga total. Os valores são inseridos em uma ferramenta computacional com capacidade de calcular parâmetros estatísticos. Na Tabela 2, os parâmetros estatísticos são apresentados: média, mediana, desvio padrão, mínimo, máximo e número de medições, para os para-raios com 8, 15 e 28 anos de envelhecimento natural em subestações.

Com base nos dados da Tabela 2, constata-se que a componente da terceira harmônica, para o para-raios com 8 anos de operação, pode variar entre 6,07 μA e 10,70 μA , com mediana de 8,33 μA . Para o para-raios com 15 anos de operação, a terceira componente harmônica da corrente pode variar entre 7,06 μA e 14,07 μA , com mediana de 9,66 μA . No mesmo sentido, para o para-raios com 28 anos de operação, a variação da terceira componente harmônica pode ser entre 11,70 μA e 19,60 μA , com mediana de 16,60 μA . Todas essas variações representam as diferentes condições ambientais referentes aos diversos dias, durante os seis meses, em que foram realizadas as medições, além das variações de tensão no ponto de medição.

2.3 Construção da Série Temporal

A série temporal foi construída utilizando os valores da terceira componente harmônica que foram extraídos dos sinais da corrente de fuga, além de ter sido considerado a estatística descritiva desses valores.

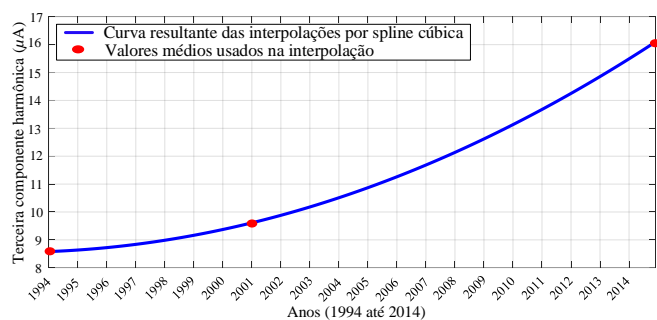


Fig. 1 Curva obtida por interpolações e valores médios da terceira componente harmônica da corrente.




Fig. 2 Sinal de ruído branco com distribuição uniforme.




Fig. 3 Representação da série temporal constituída por valores da terceira componente harmônica da corrente de fuga.

Uma série temporal é construída por meio de um conjunto de valores de uma variável organizados sequencialmente no tempo. Considerando que não foram realizadas medições sistemáticas da terceira componente da corrente de fuga total ao longo do tempo e que os dados disponíveis são valores médios da terceira componente da corrente de fuga total de para-raios com 8, 15 e 28 anos, uma estratégia foi adotada para construção da série temporal: a construção de uma série temporal de um para-raios hipotético. Com base nas emulações adotadas para os para-raios e nas variações de temperatura e tensão, adotou-se que um para-raios hipotético teria tido medições de corrente de fuga para 8, 15 e 28 anos de tempo de operação.

A partir dos três valores da terceira componente da corrente de fuga total do para-raios hipotético, realizaram-se interpolações por *spline* cúbica, devido que os três valores médios utilizados do banco de dados apresentaram variação crescente e não linear em função do tempo de operação. A interpolação possibilitou a ampliação do banco de dados para 252 valores, entre os anos de 1994 e 2014. Esses valores correspondem a

Tabela 3. Divisão dos valores da série temporal para treinamento e validação

Horizontes de tempo	Treinamento	Validação			
		12	24	36	48
Meses/amstras	204				

medições mensais, que ampliam 21 anos. A curva obtida por interpolações e os três valores médios utilizados são ilustrados na Fig. 1.

Para agregar mais informações das medições realizadas em campo aos 252 valores obtidos por interpolação, adicionou-se um sinal de ruído branco com distribuição uniforme para representar os efeitos das variações de tensão, temperatura e outros eventuais fenômenos intempestivos que podem ocorrer ao longo do tempo de operação do para-raios. Os níveis máximo e mínimo do ruído branco foram limitados pelo valor da média ponderada obtida por meio dos valores de desvio padrão associados a cada conjunto de medições. Esse sinal de ruído branco é apresentado na Fig. 2. Na Fig. 3 é apresentada a série temporal construída com os 252 valores obtidos da interpolação somada aos valores do ruído branco.

Para avaliar o desempenho dos modelos de previsão a serem apresentados na próxima seção, dividiu-se a base de dados em dois subconjuntos: treinamento e validação. Na Tabela 3 são apresentados os valores correspondentes à divisão. Manteve-se sempre o subconjunto de treinamento igual a 204 amostras. No subconjunto de validação, o número de amostras variou, com intervalos de tempo: 12, 24, 36 e 48 meses, a fim de avaliar o desempenho dos modelos em horizontes de tempo diversos.

3. Modelos de Previsão

Como este trabalho propõe uma metodologia para estimar a vida útil de para-raios por meio da aplicação de modelo de previsão de séries temporais, os modelos ANFIS e SVR foram implementados e analisados, a fim de identificar o modelo com o melhor desempenho, o qual deve constituir a metodologia proposta. A seguir serão apresentadas as configurações utilizadas durante as implementações desses modelos.

3.1 Sistema de Inferência Neuro-Fuzzy Adaptativo - ANFIS

Para aplicação dos modelos de previsão baseados em ANFIS, utilizou-se uma ferramenta computacional capaz de resolver problemas numéricos. Para tanto, usou-se a série temporal adotada neste trabalho. O banco de dados representativo da série temporal foi modificado para associar os índices (1 a 252) a ordenação por meses (1 a 12, para cada um dos anos). Assim, a série temporal e a ordenação por meses foram utilizadas como entradas para implementação do modelo. Uma parte da série foi destinada para treinamento (204 meses) e a outra para validação (12, 24, 36 e 48 meses), conforme apresentado na Tabela 3.

Os modelos baseados em ANFIS podem ser configurados de diferentes maneiras, a depender dos hiperparâmetros utilizados durante o processo de implementação, especificamente na fase de treinamento. Para realizar uma análise comparativa, três modelos baseados em ANFIS foram

Tabela 4. Características dos hiperparâmetros utilizados nos modelos ANFIS

Função de pertinência de entrada	Número de funções de pertinência de entrada	Número de regras <i>fuzzy</i>	Número de nós	Função de pertinência de saída	Número de funções de pertinência de saída	Número de épocas
Gaussiana	5	25	60	Linear	25	40
Sino Generalizada	5	25	60	Linear	25	40
Pi	5	25	60	Linear	25	40

construídos por meio de três funções de pertinência distintas. Devido à necessidade do aumento da eficiência e da grande aplicabilidade em diversos tipos de problemas, as funções de pertinência Gaussiana, Sino Generalizada e Pi foram utilizadas. Na Tabela 4 são apresentadas as características dos hiperparâmetros utilizados nos modelos ANFIS.

Decidiu-se apenas variar as funções de pertinência, pois essas funções apresentam diferentes resultados em função das características da série temporal. Isto é, para determinado conjunto de dados, haverá uma função que possibilita que o modelo apresente um melhor desempenho. Os demais hiperparâmetros foram igualmente configurados para os três modelos implementados, visto que eles contribuíram para que o modelo implementado apresentasse o melhor desempenho, tanto na fase de treinamento quanto na fase de validação, considerando a série temporal do para-raios hipotético.

Com o intuito de realizar o mapeamento de cada saída de regra *fuzzy se-então* para cada um dos três modelos implementados, gerou-se um sistema de inferência *fuzzy* do tipo Takagi-Sugeno. Assim, faz-se o mapeamento da entrada e da saída da regra por uma combinação linear das entradas.

Para a entrada do modelo, cinco funções de pertinência foram determinadas, já que esse número de funções possibilitou obter os menores erros. Como consequência do número de entradas e da quantidade de funções de pertinência, 25 regras foram utilizadas. Já para saída, utilizou-se uma função linear, a qual deve ser utilizada para compor o sistema de inferência Takagi-Sugeno.

O treinamento de cada um dos modelos implementados foi realizado com base no algoritmo híbrido de aprendizado, que resulta da combinação dos métodos de Mínimos Quadrados (OLS, do inglês *Ordinary Least Squares*) e Gradiente Descendente (GD, do inglês *Gradient Descendent*). Esse tipo de algoritmo baseia-se na retropropagação do erro, que identifica os melhores parâmetros da rede, especificamente das funções de pertinência, de modo a minimizar o erro na resposta gerada pelo modelo.

Para aplicar esse algoritmo de otimização e acelerar a identificação dos parâmetros, o conjunto de parâmetros é

decomposto em dois subconjuntos: lineares e não lineares. O primeiro conjunto é identificado pelo método OLS e o segundo pelo método GD. Dessa forma, os parâmetros consequentes do modelo foram determinados, para 40 épocas, que possibilitou alcançar o mínimo global na busca pelo menor erro, proporcionando previsões mais exatas. Após a etapa do treinamento do modelo ANFIS, as previsões foram realizadas para validação do modelo.

3.2 Regressão por Vetores de Suporte – SVR

Os modelos SVR também foram implementados em um ambiente computacional com capacidade de resolver problemas numéricos. As entradas para treinamento dos modelos baseados em SVR foram iguais às entradas empregadas nos modelos ANFIS. De forma semelhante à implementação do modelo ANFIS, uma parte da série também foi destinada para treinamento (204 meses) e a outra para validação (12, 24, 36 e 48 meses), como apresentado na Tabela 3.

Nas implementações dos modelos baseados em SVR também foram utilizados diferentes hiperparâmetros. Desta vez, diferentes funções *kernel* foram utilizadas, com o intuito de verificar quais delas poderiam fornecer os melhores resultados com base nas métricas de desempenho adotadas. Para tanto, três funções foram empregadas, sendo elas: Gaussiana, Linear e Polinomial. Decidiu-se variar apenas a função *kernel*, pois a escolha desse tipo de função deve ser de acordo com a dinâmica da série temporal e outras entradas que podem ser utilizadas para construção do modelo.

Durante a fase de treinamento, fez-se necessário a padronização dos dados, a fim de evitar sensibilidade às escalas dos dados medidos que constitui a série temporal adotada. Durante essa etapa, escolheu-se três tipos diferentes de funções *kernel*, para verificar qual das funções utilizadas forneceria os melhores resultados de previsão.

Os hiperparâmetros apresentados na Tabela 5 foram determinados por meio de iterações tendo como objetivo o alcance do valor de ϵ , com exceção das funções *kernel* e constante de regularização. Considerando isso, foram

Tabela 5. Especificações dos hiperparâmetros dos modelos baseados em SVR

Função <i>kernel</i>	Bias, b	Escala do kernel, γ	Constante de regularização, C	Epsilon, ϵ	Iterações
Linear	$1,03 \times 10^{-5}$	1,86	1	$1,87 \times 10^{-7}$	20
Polinomial	$1,02 \times 10^{-5}$	1,68	1	$1,87 \times 10^{-7}$	20
Gaussiana	$1,05 \times 10^{-5}$	1,44	$1,87 \times 10^{-7}$	$1,87 \times 10^{-7}$	20

realizadas 20 iterações para que esses valores fossem alcançados, para aplicação do SRM e o Método de Multiplicadores de Lagrange. Os valores usados para constante de regularização, C , foram valores determinados pela ferramenta computacional. Por exemplo, para as funções *kernel* Linear e Polinomial, adota-se essa constante sendo igual a 1. Já para a função *kernel* Gaussiana, o valor de C é determinado em função de γ (parâmetro da função *kernel*).

4. RESULTADOS E DISCUSSÕES

Os resultados obtidos por meio das implementações dos modelos ANFIS e SVR são avaliados de forma quantitativa com base nos valores do coeficiente de determinação, para verificar se os modelos se ajustaram à série, e do Erro Percentual Absoluto Médio (MAPE, do inglês *Mean Absolute Percentage Error*), para mensurar a acurácia das previsões realizadas. O coeficiente de determinação é definido em (1) e o MAPE, definido em (2).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\%, \quad (1)$$

$$R^2 = 1 - \frac{SSE}{SST},$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (2)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y}_i)^2.$$

Em (1) e (2), n representa o número de pontos treinados e previstos, y_i representa os valores medidos da série temporal e \hat{y}_i representa os valores treinados e previstos dos modelos. E SSE é a soma dos quadrados dos erros (do inglês *Sum of Squared Errors*), que representa a variação total do que não consegue ser ajustada à série temporal construída, e SST é a soma dos quadrados totais (do inglês *Total Sum of Squares*), que representa a variação total de y_i com relação à sua média.

Como forma de interpretação do MAPE, quanto menor o seu valor, mais confiável é a previsão realizada. O coeficiente de determinação, diferentemente dos erros, é empregado para avaliar a qualidade do ajuste do modelo à série adotada como referência, na fase de treinamento. A faixa de variação possível do R^2 é apresentada em (3), sabendo que quanto maior o valor desse coeficiente, melhor é o ajuste do modelo à série temporal (Hyndman & Athanasopoulos 2018).

$$0 \leq R^2 \leq 1. \quad (3)$$

Os valores de R^2 obtidos durante a etapa de treinamento dos modelos ANFIS e SVR são apresentados na Tabela 6. Já os erros obtidos para os quatro horizontes de tempo adotados são ilustrados nas Figs. 3 e 4.

Diante da Tabela 6, para o modelo ANFIS, o melhor ajuste ocorre com a função de pertinência Gaussiana, já que o valor do coeficiente de determinação para este caso é o maior, dentre os valores obtidos para esse tipo de modelo-base. Já para o modelo SVR, constata-se que o modelo SVR com função Gaussiana apresenta o melhor ajuste, pois o valor de R^2 é o maior, dentre os obtidos para esse tipo de modelo, apesar de

Tabela 6. Valores do coeficiente de determinação dos modelos de previsão baseados em ANFIS e SVR, para a fase de treinamento (204 meses)

ANFIS	R^2	Gaussiana	Sino generalizada	Pi
		0,9971	0,9903	0,9598
SVR	R^2	Gaussiana	Linear	Polinomial
		0,9962	0,9945	0,9929

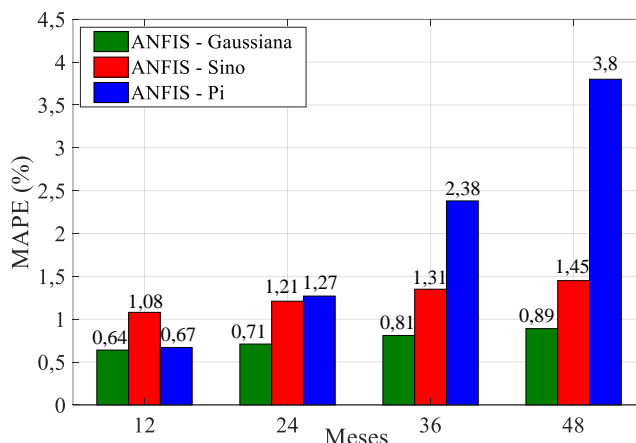


Fig. 3 Dinâmica dos valores do MAPE para quatro horizontes de tempo, considerando a aplicação dos modelos baseados em ANFIS com as funções Gaussiana, Sino Generalizada e Pi.

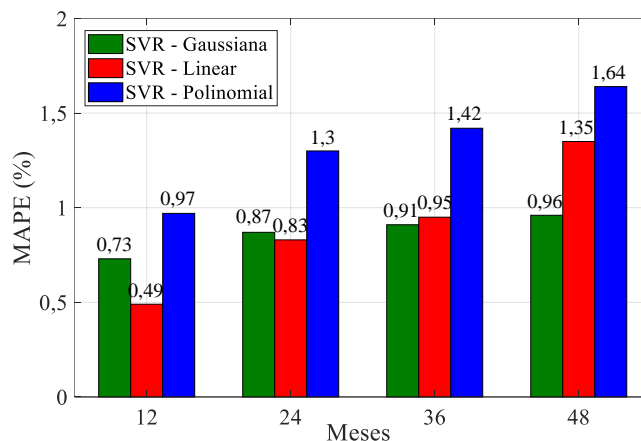


Fig. 4 Dinâmica dos valores do MAPE para quatro horizontes de tempo, considerando a aplicação dos modelos baseados em SVR com as funções Gaussiana, Linear e Polinomial.

que o modelo SVR com função Linear também apresentou um ótimo ajuste.

Na fase de previsão dos modelos baseados em ANFIS, com base nos valores do MAPE, o modelo ANFIS com função Gaussiana apresentou melhor desempenho em relação aos demais modelos, uma vez que os valores dos erros obtidos foram menores, para os quatro horizontes de tempo considerados. Com relação aos resultados de previsão dos modelos baseados em SVR, para os horizontes de 12 e 24 meses, o modelo SVR com função Linear apresentou o melhor

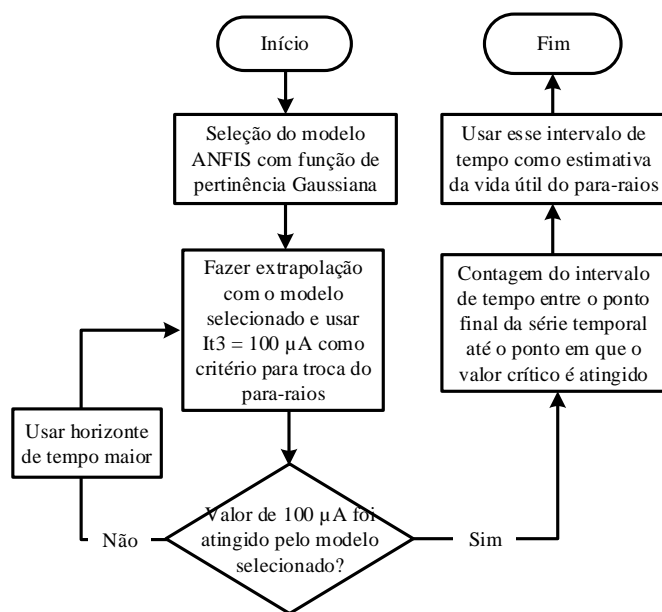


Fig. 5 Fluxograma da metodologia proposta para estimar a vida útil do para-raios hipotético.

desempenho, pois obteve os menores valores de erros. Contudo, para os horizontes de tempo de 36 e 48 meses, o modelo SVR com função Gaussiana apresentou desempenho superior em relação aos demais, tendo em vista os menores valores dos erros.

Com base nos resultados quantitativos apresentados nas Figs. 3 e 4, é evidente que os erros não aumentam de forma expressiva em função do horizonte do tempo. Essa análise é válida para os modelos baseados em ANFIS, que usam as funções Gaussiana e Sino Generalizada, bem como para os três modelos baseados em SVR. Para o caso do modelo ANFIS com função Pi, verifica-se que os erros crescem de forma significativa em função do horizonte de tempo.

Como o modelo ANFIS com função de pertinência Gaussiana apresentou o melhor desempenho nas fases de treinamento (maior coeficiente de determinação) e validação (menores valores do MAPE), ele deve ser utilizado para constituir a metodologia proposta para estimar a vida útil do para-raios hipotético. A metodologia é representada por meio do fluxograma apresentado na Fig. 5.

Tendo em vista o fluxograma representativo da metodologia proposta para estimar a vida útil de para-raios de ZnO apresentado na Fig. 5, a metodologia inicia com a seleção e implementação do modelo ANFIS com função de pertinência Gaussiana, considerando também a utilização dos outros hiperparâmetros utilizados neste trabalho. Já que esse modelo já foi treinado e validado, deve ser utilizado para realizar extrapolação até atingir o valor de $100 \mu\text{A}$. Dessa forma, a vida útil do para-raios é estimada por meio da contagem do intervalo de tempo iniciando imediatamente após o último valor da série temporal (a partir do primeiro mês de 2015) até o ponto em que o valor crítico é alcançado. O ponto imediatamente após o fim da série é o primeiro mês de 2015, pois a série abrange o intervalo iniciando de 1994 até 2014.

Com base no modelo ANFIS, com função de pertinência Gaussiana, realizou-se uma extrapolação com previsão de 18




Fig. 6 Previsão para 216 meses à frente pelo modelo ANFIS com função de pertinência Gaussiana, para estimar a vida útil do para-raios.

anos (216 meses) à frente, conforme apresentado na Fig. 6. Adotou-se esse horizonte de previsão, pois, com base no modelo mais exato, verificou-se que esse é o intervalo de tempo necessário para que a terceira componente harmônica atinja $100 \mu\text{A}$.

Tendo como referência a previsão realizada pelo modelo ANFIS com função Gaussiana, que é apresentada na Fig. 6, estima-se que o para-raios possuiria aproximadamente 14 anos de vida útil, caso a análise fosse realizada no ano de 2015, já que a série temporal abrange desde 1994 até 2014. Após agosto de 2028, a série poderia ultrapassar o valor de $100 \mu\text{A}$, de modo que o para-raios poderia apresentar falhas antes ou no momento do surto elétrico.

Considerando que a previsão da vida útil é uma atividade dinâmica, a sua estimativa a partir do período considerado pode sofrer alterações, desde que novas medições de sinais de corrente sejam adicionadas ao banco de dados. Isso é a principal vantagem da metodologia, pois o modelo ANFIS permite ser alimentado com novos dados, de modo que ele vai incorporá-los. Assim, o modelo vai sendo ajustado ao novo conjunto de dados.

4. CONCLUSÕES

Neste trabalho, propôs-se uma metodologia que emprega o modelo ANFIS com função de pertinência Gaussiana para estimar a vida útil de para-raios de ZnO, com base na análise da série temporal constituída pelos valores da terceira componente harmônica da corrente de fuga associada ao para-raios hipotético.

Os resultados obtidos pelos modelos SVR e ANFIS foram avaliados, para que o modelo mais exato fosse selecionado e utilizado para compor a metodologia proposta. Considerando que o modelo ANFIS com função de pertinência Gaussiana apresentou o melhor resultado, ele foi usado para compor a metodologia.

Por meio da metodologia proposta foi possível estimar o tempo de vida útil do para-raios hipotético associado à série empregada neste trabalho. Verificou-se que o tempo de vida útil seria de aproximadamente 14 anos.

Embora tenha sido utilizado $100 \mu\text{A}$ como critério para estimar a vida útil do equipamento, é importante que ele não seja adotado de forma absoluta para outros para-raios instalados no SEP, pois esse critério foi adequado para os para-raios com as

especificações utilizadas neste trabalho, especificamente para o para-raios hipotético.

Com a metodologia proposta, o gerenciamento de ativos instalados no SEP, especialmente os para-raios de ZnO, pode ser otimizado por meio da aplicação de previsão de séries temporais baseado no modelo ANFIS com função de pertinência Gaussiana. Dessa forma, a partir do conhecimento da vida útil dos para-raios, manutenções preventivas, tal como a substituição do equipamento, podem ser realizadas para evitar desligamentos não programados.

AGRADECIMENTOS

Os autores agradecem a todos que compõem o Laboratório de Alta Tensão (LAT) pertencente à UFCG, por todo o apoio e dedicação na construção deste trabalho; à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Programa de Excelência Acadêmica (PROEX).

REFERÊNCIAS

- Cofeen, L. T., McBride, J. E. (1991). High voltage AC resistive current measurements using a computer based digital watts technique. *IEEE Transactions on Power Delivery*, v. 6 (n. 2), p. 550-556, p. 550-556.
- Dobrić, G., Žarković, M. (2020). Fuzzy expert system for metal-oxide surge arrester condition monitoring. *Electrical Engineering*, p. 1-11.
- Fu, Z., Wang, J., Bretas, A., Ou, Y., and Zhou G. (2017). Measurement method for resistive current components of metal oxide surge arrester in service. *IEEE Transactions on Power Delivery*, v. 33 (n. 5), p. 2246-2253.
- Gilat, A., Subramaniam, V. (2013). *Numerical methods for engineers and scientists: an introduction with applications using MATLAB*, 3ª ed., p. 251-298. Wiley Global Education, Columbus, O., USA.
- Haykin, S. O. (2008). *Neural networks and learning machines*, 3ª ed., p. 268-303. Prentice Hall: Upper Saddle River, NJ.
- Heinrich, C., Hinrichsen, V. (2001). Diagnostics and monitoring of metal-oxide surge arresters in highvoltage networks-comparison of existing and newly developed procedures. *IEEE Transactions on Power Delivery*, v. 16 (n. 1) p. 138-143.
- Hinrichsen, V. (1997). Monitoring of high voltage metal oxide surge arresters. *VI Jornadas Internacionales de Aislamiento Electrico*, p. 22-23.
- Hinrichsen, V. (2012). *Metal-oxide surge arresters in high-voltage power systems, Fundamentals*. SiemensAG, Erlangen, DE, 2012.
- Hong, Y. Y., Wu, C. P. (2012). Day-ahead electricity price forecasting using a hybrid principal component analysis network. *Energies*, v. 5 (n. 11), p. 4711-4725.
- Hyndman, R. J., Athanasopoulos, G. (2018). *forecasting: principles and practice*. OTexts.
- IEC 60099-5. *Surge arresters - part 5: selection and application recommendations*. [S.l.], 2013.
- Khan, A. N., Nadeem, M. A., Hussain, M. S., Aslam, M., Bazmi, A. A. (2019). A forecasting model approach of sustainable electricity management by developing adaptive neuro-fuzzy inference system. *Environmental Science and Pollution Research*, p. 1-12.
- Khodsuz, M., Mirzaie, M. (2015). Monitoring and identification of metal-oxide surge arrester conditions using multi-layer support vector machine. *IET Generation, Transmission & Distribution*, v. 9 (n. 16) p. 2501-2508.
- Lima júnior, G. B. (2014). Monitoramento de Para-raios de Óxido de Zinco em Campo. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de Campina Grande, Campina Grande, 2014.
- Lira, G. R. S., Costa, E. G. (2013). MOSA monitoring technique based on analysis of total leakage current. *IEEE Transactions on Power Delivery*, v. 28 (n. 2), p. 1057-1062.
- Lira, G. R. S., Barbosa, V. R. N., Brito, V. S., Costa, E. G., Amorim filho, C. R., and Maia, (2018). M. J. Methodology to evaluate the performance of metal-oxide surge arresters monitoring techniques based on the resistive leakage current. *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*, p. 1-6.
- Metwally, I. A., Eladawy, M., and Feilat, E. A. (2017). Online condition monitoring of surge arresters based on third-harmonic analysis of leakage current. *IEEE Trans. on Dielectrics and Electrical Insulation*, vol. 24 (n. 4), p. 2274-2281.
- Muremi, L., Bokoro, P. (2020). Failure prediction of metal oxide arresters using artificial neural networks. *2020 IEEE Electrical Insulation Conference (EIC)*, p. 58-61.
- Sakshaug, E. C. (1991). A brief history of ac surge arresters. *IEEE Power Engineering Review*, v. 11 (n. 8), p. 11-1.
- Shirakawa, S., Endo, F., Kitajima, H., Kobayashi, S., Kurita, K., Goto, K., Sakai, M. (1998). Maintenance of surge arrester by a portable arrester leakage current detector. *IEEE Trans. Power Del.*, v. 3 (n. 3), p. 998-1003.
- Suparta, W. and Alhasa, K. M. (2016). *Modeling of tropospheric delays using ANFIS*. Springer Nature, p. 5-14, Basel-Stadt, CH.
- Tridelta. (2002). *Diagnostic appliance for evaluating the operational state of metal oxide arresters - 1349.8 - 01 MI(E)*, 5ª ed., p. 1-8, Tridelta Meidensha GmbH, Hermsdorf, Thuringia, DE.
- Wen, Y., Zhou, C. (2004). A novel method for predicting the lifetime of MOV. *IEEE Transactions on Power Delivery*, v. 19 (n. 4), p. 1688-1691.
- Zaghloul, M. S., Hamza, R. A., Iorhemen, O. T., Tay, J. H. (2020). Comparison of adaptive neuro-fuzzy inference systems (ANFIS) and support vector regression (SVR) for data-driven modelling of aerobic granular sludge reactors. *Journal of Environmental Chemical Engineering*, v. 8 (n. 3), p. 103742.
- Zhou L., Xie L., Tong X. J. (2007). Recursive neural networks and its application in forecasting the state of electric power equipment. *Sixth International Conference on Machine Learning and Cybernetics*.