

CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA



Universidade Federal
de Campina Grande

VANDILSON RODRIGO DO NASCIMENTO BARBOSA




Centro de Engenharia
Elétrica e Informática

TRABALHO DE CONCLUSÃO DE CURSO

APLICAÇÃO DE TÉCNICAS DE PREVISÃO DE SÉRIES TEMPORAIS PARA
DETERMINAÇÃO DA VIDA ÚTIL DE PARA-RAIOS DE ÓXIDO DE ZINCO



Departamento de
Engenharia Elétrica



Campina Grande - PB
Dezembro de 2019

VANDILSON RODRIGO DO NASCIMENTO BARBOSA

APLICAÇÃO DE TÉCNICAS DE PREVISÃO DE SÉRIES TEMPORAIS PARA DETERMINAÇÃO DA
VIDA ÚTIL DE PARA-RAIOS DE ÓXIDO DE ZINCO

*Trabalho de Conclusão de Curso submetido à
Unidade Acadêmica de Engenharia Elétrica da
Universidade Federal de Campina Grande
como parte dos requisitos necessários para a
obtenção do grau de Bacharel em Ciências no
Domínio da Engenharia Elétrica.*

Área de Concentração: Proteção de Equipamentos Elétricos

Orientador:

Professor George Rossany Soares de Lira, D. Sc.

Campina Grande

2019

VANDILSON RODRIGO DO NASCIMENTO BARBOSA

APLICAÇÃO DE TÉCNICAS DE PREVISÃO DE SÉRIES TEMPORAIS PARA DETERMINAÇÃO DA
VIDA ÚTIL DE PARA-RAIOS DE ÓXIDO DE ZINCO

*Trabalho de Conclusão de Curso submetido à
Unidade Acadêmica de Engenharia Elétrica da
Universidade Federal de Campina Grande
como parte dos requisitos necessários para a
obtenção do grau de Bacharel em Ciências no
Domínio da Engenharia Elétrica.*

Área de Concentração: Gerenciamento de Ativos no Setor Elétrico

Aprovado em: / /

Professor Pablo Bezerra Vilar, D. Sc.
Universidade Federal de Campina Grande
Avaliador, UFCG

Professor George Rossany Soares de Lira, D. Sc.
Universidade Federal de Campina Grande
Orientador, UFCG

Dedico este trabalho à minha mãe, Vandeilza Nascimento, que, com muito carinho e apoio, não mediu esforços para que eu chegasse até esta etapa de minha vida.

AGRADECIMENTOS

Agradeço, em primeiro lugar, a Deus, por estar comigo em todos os momentos desta minha longa jornada, sempre me dando forças nas horas em que pensei em desistir. Pelo dom da vida e por todas as oportunidades que Ele deu para mim.

Agradeço à minha família, em especial, à minha mãe, por todo amor, carinho, cuidado e por todo esforço para criar e educar a mim e ao meu irmão, nos proporcionando sempre o melhor que podia. Ela tem sido uma das principais motivações para buscar um futuro melhor. Ademais, minha tia, Vangeilsa Nascimento, merece também destaque, pois tenho imensa gratidão pelos sábios conselhos e apoio nos momentos mais críticos, além de ser um exemplo de sucesso que me inspira bastante. Ao meu irmão, João, e também aos meus primos, Victor Nascimento e Camila Nascimento, por me apoiarem nas minhas decisões e durante o período da graduação.

Agradeço a todos os professores do Departamento de Engenharia Elétrica (DEE) da Universidade Federal de Campina Grande (UFCG) e outras instituições, que contribuíram direta ou indiretamente para minha formação. Dentre esses professores, três deles merecem destaque: George Lira, Valdemir Brito e Edson Costa. Ao primeiro e ao segundo, por serem os meus orientados durante a graduação, em projetos de pesquisa, pela paciência, atenção, compreensão e as várias oportunidades que foram oferecidas para mim, além dos diversos conselhos e experiências compartilhadas. Ao terceiro, pelo apoio, conselhos, oportunidades e dedicação com relação, sobretudo, aos alunos com vínculo ao Laboratório de Alta Tensão (LAT) da UFCG.

Aos colegas e amigos da graduação, agradeço por todo o apoio, por toda ajuda recebida e pelos conhecimentos compartilhados. Tenho enorme gratidão pelos que fazem o Armário, pela amizade, apoio e conversas descontraídas no dia a dia da graduação.

Agradeço aos que fazem o LAT, considerando os professores, alunos (de graduação e pós-graduação) e técnicos, pela amizade, conhecimentos (técnicos e gerais) e outras experiências compartilhadas durante as conversas no âmbito do laboratório.

E, ainda, agradeço aos que contribuíram para elaboração deste trabalho, de forma direta ou indireta, com destaque para Marianna Dias, Thainá Xavier e Cícero Amorim Filho, além dos professores já citados anteriormente.

“Se eu vi mais longe, foi por estar de pé sobre ombros de gigantes.”

Isaac Newton.

RESUMO

Os para-raios de Óxido de Zinco (ZnO) vêm sendo empregados com a finalidade de aumentar a confiabilidade, economia e continuidade de operação dos Sistemas Elétricos de Potência (SEPs). Tendo em vista a importância dos para-raios para os SEPs, faz-se necessário o estudo, desenvolvimento e otimização de técnicas para previsão da vida útil de para-raios de ZnO. Neste trabalho, apresenta-se um estudo avaliativo de técnicas que empregam modelos puros e combinacionais para previsão do comportamento de Séries Temporais (STs), com a finalidade de serem empregadas na estimativa da vida útil de para-raios de ZnO. Apesar de existirem diversas técnicas de previsão de STs na literatura, há carência de técnicas destinadas para estimação da vida útil de para-raios de ZnO. Dentre os indicadores sensíveis ao nível de degradação dos para-raios, os que podem ser utilizados para constituir a ST são o conteúdo harmônico da corrente de fuga total e sua componente resistiva, tendo em vista que esses indicadores são os mais empregados pelos SEPs. Para realização deste trabalho, inicialmente foi construído um banco de dados constituído por STs com informações da terceira componente harmônica da corrente de fuga total de para-raios de ZnO. Em seguida, as técnicas de previsão de STs foram implementadas em uma plataforma computacional. As técnicas de previsão de STs selecionadas para implementação empregam modelos baseados em inteligência artificial, sendo o foco de análise o sistema *Neuro-Fuzzy*, a rede de Memória Longa de Curto Prazo e a Máquina de Vetores de Suporte. A técnica baseada em modelo combinacional utiliza esses três tipos de inteligência artificial para realizar previsão do comportamento de STs. Por fim, a avaliação do desempenho de cada uma das técnicas implementadas foi realizada mediante o emprego dos indicadores de desempenho adotados, tais como: erro quadrático médio, erro absoluto médio e erro percentual absoluto médio. Os testes realizados até o momento indicam que as técnicas implementadas apresentam resultados satisfatórios nas previsões realizadas, sobretudo com relação à técnica que emprega modelo combinacional. Dessa forma, obteve-se um panorama geral das técnicas de estimação da vida útil dos para-raios de ZnO, contribuindo, sobretudo, para o gerenciamento de ativos do SEP.

Palavras-chave: para-raios de ZnO; estimação de vida útil; gerenciamento de ativos.

ABSTRACT

Metal Oxide Surge Arresters (MOSAs) have been employed in order to increase the reliability, economy and continuity of operation of Electric Power Systems (EPSs). Considering the importance of the MOSAs for EPSs, it is necessary to study, develop and optimize techniques for forecasting the MOSA lifetime. This paper presents an evaluative study of techniques that employ pure and hybrid models to forecast the behavior of Time Series (TSs), in order to apply those techniques in the estimation of MOSA lifetime. Although there are several techniques in the literature that use pure and hybrid models for forecasting, there is lack of designed techniques to forecast the MOSA lifetime. Among the sensitive indicators to the MOSA degradation level, the ones that can be used to form the TS are the harmonic content of the total leakage current and its resistive component, considering that these indicators are the most used by the EPSs. To perform this work, a database was initially built with TSs with information on the third harmonic component of the MOSA total leakage current. Then, the TS forecasting techniques were implemented on a computational platform. The selected TS forecasting techniques for implementation employ models based on artificial intelligence, with the focus of analysis being the Neuro-Fuzzy system, the Long Short-Term Memory network and the Support Vector Machine. The combinational model-based technique uses these three types artificial intelligence to perform TS behavior forecasting. Finally, the performance evaluation of each of the implemented techniques was accomplished using the adopted performance indicators, such as: mean square error, mean absolute error and mean absolute percentage error. Tests performed so far indicate that the implemented techniques present satisfactory results in the forecasting, especially in relation to the technique that employs a combinational model. Thus, an overview of the forecasting techniques of the MOSA lifetime was obtained, mainly contributing to the asset management of the EPS.

Keywords: metal oxide surge arrester; lifetime estimation; asset management.

LISTA DE ILUSTRAÇÕES

Figura 1 – Ilustração da evolução dos para-raios. (a) com centelhador e dielétrico a ar; (b) centelhador em série com blocos não lineares; (c) centelhador com alongador de arco em série com blocos não lineares; (d) formado apenas por resistores não lineares.	19
Figura 2 – Representação da estrutura de um para-raios de ZnO com invólucro de porcelana.	20
Figura 3 – Varistores de ZnO em diversas dimensões.	21
Figura 4 – Curva característica típica do para-raios de ZnO.	22
Figura 5 – Sinais da tensão aplicada e corrente de fuga total de um para-raios de ZnO operando na região de baixas correntes.	22
Figura 6 – Modelo elétrico simplificado de um para-raios de ZnO.	24
Figura 7 – Corrente de fuga típica de um para-raios de ZnO sob condições controladas.	25
Figura 8 – Comportamento relativo da componente resistiva, da componente harmônica de 3ª ordem da corrente de fuga total e da perda de potência em função da relação entre a tensão aplicada ao para-raios e a tensão de operação contínua.	26
Figura 9 – Comportamento relativo da componente resistiva, da componente harmônica de 3ª ordem da corrente de fuga total e da perda de potência em função da temperatura.	26
Figura 10 – Comportamento da ST ao longo de 21 anos (252 meses), desde 1995 até 2015.	28
Figura 11 – Componente de tendência da ST analisada neste trabalho, com valores da terceira componente harmônica da corrente de fuga total.	29
Figura 12 – Componente sazonal da ST considerada neste trabalho, constituída por valores da terceira componente harmônica da corrente de fuga total.	30
Figura 13 – Componente aleatória da ST considerada neste trabalho, constituída por valores da terceira componente harmônica da corrente de fuga total.	30
Figura 14 – Gráfico da FAC para constatar o decaimento lento.	33
Figura 15 – Hiperplano de separação ótima e seus hiperplanos de suporte.	38
Figura 16 – Ilustração do modelo da SVR, considerando as variáveis de folga, vetores de suporte e o hiperplano.	39
Figura 17 – Aplicação do procedimento de <i>kernel</i> em um espaço de características.	39
Figura 18 – Arquitetura ANFIS.	42
Figura 19 – Representação de uma célula LSTM.	44
Figura 20 – Representação de uma célula LSTM sendo replicada no tempo.	44
Figura 21 – Fluxograma da metodologia empregada neste trabalho.	52
Figura 22 – Previsões para 24 meses à frente, obtidas pela técnica A, com o emprego da SVM.	60
Figura 23 – Previsões para 48 meses à frente, obtidas pela técnica A, com o emprego da SVM.	60
Figura 24 – Previsões para 24 meses à frente, obtidas pela técnica B, com o emprego da NFS.	62
Figura 25 – Previsões para 48 meses à frente, obtidas pela técnica B, com o emprego da NFS.	62
Figura 26 – Previsões para 24 meses à frente, obtidas pela técnica C, com o emprego da rede LSTM.	64
Figura 27 – Previsões para 48 meses à frente, obtidas pela técnica C, com o emprego da rede LSTM.	64
Figura 28 – Previsões para 24 meses à frente, obtidas pela técnica D, com o emprego do modelo combinacional.	66
Figura 29 – Previsões para 48 meses à frente, obtidas pela técnica D, com o emprego do modelo combinacional.	66

LISTA DE TABELAS

Tabela 1 – Vantagens e desvantagens dos modelos de previsão quantitativos.....	35
Tabela 2 – Dados técnicos dos para-raios de ZnO.	54
Tabela 3 – Valores dos pesos do modelo combinacional para horizontes de previsão com 24 e 48 meses à frente.	57
Tabela 4 – Comparação entre o desempenho apresentado por cada uma das técnicas implementadas.....	68

LISTA DE ABREVIATURAS E SIGLAS

AC – *Alternating Current.*

ANFIS – *Adaptative-Network-Based Fuzzy Inference System.*

ANN – *Artificial Neural Networking.*

AR – *Autoregressive.*

MA – *Moving Average.*

ARMA – *Autoregressive Moving Average.*

ARIMA – *Autoregressive Integrated Moving Average.*

CHESF – *Companhia Hidrelétrica do São Francisco.*

DC – *Direct Current.*

DEE – *Departamento de Engenharia Elétrica.*

FAC – *Função de Autocorrelação.*

GA – *Genetic Algorithm.*

LAT – *Laboratório de Alta Tensão.*

LSTM – *Long Short-Term Memory.*

MAE – *Mean Absolute Error.*

MAPE – *Mean Absolute Percentage Error.*

MCOV – *Maximum Continuous Operating Voltage.*

MSE – *Mean Squared Error.*

NFS – *Neuro-Fuzzy System.*

NBI – *Nível Básico de Isolamento.*

NV – *Nominal Voltage.*

RBF – *Radial Basis Function*

RMS – *Root Mean Square.*

RNN – *Recurrent Neural Network.*

SiC – *Carboneto de Silício.*

SVR – *Support Vector Regression.*

SVM – *Support Vector Machine.*

SVR – *Support Vector Regression.*

ST – *Série Temporal.*

SEP – *Sistema Elétrico de Potência.*

TCC – Trabalho de Conclusão de Curso.

UFCG – Universidade Federal de Campina Grande.

ZnO – Óxido de Zinco.

SUMÁRIO

1	Introdução.....	14
1.1	Objetivos.....	16
1.2	Estrutura do Texto.....	16
2	Fundamentação Teórica.....	18
2.1	Para-raios de ZnO.....	18
2.1.1	Aspectos Construtivos.....	19
2.1.2	Características Elétricas.....	21
2.1.3	Principais Parâmetros.....	22
2.1.4	Propriedades da Corrente de Fuga.....	23
2.2	Séries Temporais.....	27
2.3	Conceitos Básicos de Processos Estocásticos.....	31
2.3.1	Estacionariedade.....	32
2.3.2	Funções de Autocovariância e Autocorrelação.....	32
2.4	Modelos de Previsão de Séries Temporais.....	34
2.4.1	SVM.....	36
2.4.2	NFS.....	40
2.4.3	LSTM.....	43
3	Revisão Bibliográfica.....	46
3.1	Levantamento do Estado da Arte Relacionado à Estimação da Vida Útil de Para-raios de ZnO	46
4	Metodologia.....	52
4.1	Constituição do Banco de Dados de Séries Temporais.....	53
4.2	Técnicas Utilizadas para Previsão de Séries Temporais.....	53
4.2.1	Técnica A.....	54
4.2.2	Técnica B.....	54
4.2.3	Técnica C.....	55
4.2.4	Técnica D.....	55
4.3	Indicadores de Desempenho.....	57
5	Resultados e Análises.....	59
5.1	Resultados Obtidos pela Técnica A.....	60
5.2	Resultados Obtidos pela Técnica B.....	61
5.3	Resultados Obtidos pela Técnica C.....	63
5.4	Resultados Obtidos pela Técnica D.....	65
5.5	Comparação entre os Resultados Obtidos pelas Técnicas A, B, C e D.....	67
6	Conclusões.....	69
	Referências.....	71

1 INTRODUÇÃO

Os para-raios de Óxido de Zinco (ZnO) são equipamentos utilizados na proteção dos Sistemas Elétricos de Potência (SEPs). Para tanto, esses equipamentos de proteção são responsáveis por limitar as sobretensões de origem externa (descargas atmosféricas) ou interna (operações de manobra) a níveis suportáveis por outros equipamentos elétricos empregados nas subestações, como também nas linhas de transmissão e distribuição (GUPTA, 1990; BARGIGIA *et al.*, 1986).

Os para-raios de ZnO vêm sendo empregados há mais de 40 anos com a finalidade de aumentar a confiabilidade, economia e continuidade de operação dos sistemas elétricos (BRITO, 2016). Assim, faz-se necessário o estudo, desenvolvimento e otimização de técnicas para previsão de sua vida útil quando instalado em campo, uma vez que eventuais falhas nos para-raios podem conduzir a desligamentos, programados e não programados, e danos a outros equipamentos de uma subestação.

A partir de meados do decênio de 1970, deu-se início a utilização, em campo, dos para-raios de ZnO sem centelhadores (SAKSHAUG, 1991). Desde então, várias técnicas de monitoramento e diagnóstico de para-raios de ZnO vêm sendo desenvolvidas com o objetivo de minimizar as consequências causadas pela falha de para-raios (CARLSON *et al.*, 1986; SHIRAKAWA *et al.*, 1988; HEINRICH & HINRICHSEN, 2001; ZHAO *et al.*, 2005; LIRA, 2007; IEC, 2013; LIRA *et al.*, 2014; KHODSUZ & MIRZAIE, 2015; HAN *et al.*, 2016; HOANG *et al.*, 2018). No entanto, a previsão da vida útil desses equipamentos tornou-se mais relevante para o SEP, em relação ao monitoramento e diagnóstico, já que permite o gerenciamento de ativos do sistema elétrico (YUANFANG *et al.*, 2001; WEN & ZHOU, 2004; KANNUS & LAHTI, 2005; KIM, 2015; BOKORO & JANDRELL, 2016; DOORSAMY & BOKORO, 2018). Nesse sentido, as áreas de proteção de equipamentos de alta tensão e gerenciamento de ativos do sistema elétrico, sobretudo com relação aos para-raios, carecem de estudos que auxiliem na escolha das técnicas mais promissoras para previsão da vida útil desses equipamentos.

A previsão de eventos é normalmente realizada por meio da previsão do comportamento de Séries Temporais (STs), baseada nas observações anteriores da variável a prever. As técnicas convencionais de previsão de STs se baseiam em modelos

estatísticos, inteligência artificial e algoritmos genéticos (CORTEZ, 1997; BALLINI, 2000; LIU *et al.*, 2012; ZHOU *et al.*, 2007; HONG, 2018). Entretanto, na literatura há carência de estudos que empregam técnicas de previsão de STs para estimar a vida útil de para-raios de ZnO.

Diversos trabalhos já tentaram estimar a vida útil de para-raios de ZnO, sem utilizar técnicas de previsão de STs (FUJIWARA *et al.*, 1982; CARLSON *et al.*, 1986; RINGLER *et al.*, 1997; YUANFANG *et al.*, 2001; WEN & ZHOU, 2004; KANNUS & LAHTI, 2005; KIM, 2015; BOKORO & JANDRELL, 2016; DOORSAMY & BOKORO, 2018). Esses trabalhos se baseiam no comportamento da corrente de fuga, temperatura, perda de potência e parâmetros derivados dessas grandezas. Para a validação dessas técnicas, geralmente, realizam-se ensaios em laboratório de alta tensão, aplicando-se níveis de sobretensões e impulsos de corrente, a fim de simular estresses elétricos indesejados sobre o para-raios, o que pode diminuir a vida útil do mesmo que é garantida pelo fabricante.

Os trabalhos que propõem formas de estimar a vida útil de para-raios de ZnO se baseiam no comportamento de uma variável relacionada ao seu nível de degradação. No mesmo sentido, diversos trabalhos destinados ao monitoramento e diagnóstico de para-raios a ZnO foram propostos, os quais são classificados com base no indicador sensível ao nível de degradação de para-raios (HEINRICH & HINRICHSEN, 2001; IEC 60099-5, 2013; LIRA *et al.*, 2017): medição de corrente de fuga, análise de imagens termográficas, medição de descargas parciais e identificação de rádio interferência e ruídos sônicos. As três primeiras classes de técnicas de monitoramento são as mais eficazes e utilizadas pelas empresas de energia elétrica, sendo muitas vezes empregadas em conjunto. Dessa forma, é imprescindível a investigação desses indicadores, bem como, das técnicas que podem ser empregadas para previsão de STs baseadas nesses indicadores.

Neste trabalho, apresentar-se-á um estudo avaliativo de técnicas de previsão de STs que empregam modelos puros e combinacionais baseados em inteligência artificial, a fim de serem empregadas na estimativa da vida útil de para-raios de ZnO. Para realizar a avaliação das técnicas, os modelos empregados pelas técnicas e os seus indicadores de desempenho são analisados. As STs utilizadas nas implementações computacionais são baseadas em sinais da corrente de fuga total que percorre o para-raios.

1.1 OBJETIVOS

O objetivo geral deste trabalho é propor um estudo avaliativo de técnicas de previsão de STs, para serem empregadas na estimação da vida útil de para-raios de ZnO, a fim de viabilizar a gestão de ativos do SEP.

Os objetivos específicos deste trabalho são:

- estudar a viabilidade de utilizar previsão de ST para estimar a vida útil de para-raios de ZnO;
- analisar os indicadores do nível de degradação de para-raios de ZnO mais promissores para serem utilizados como ST no processo de estimação da vida útil de para-raios;
- avaliar as técnicas de previsão de STs baseadas na aplicação de modelos puros e combinacionais, por meio dos indicadores de desempenho adotados.

1.2 ESTRUTURA DO TEXTO

Este Trabalho de Conclusão de Curso (TCC) está dividido em seis capítulos, considerando este capítulo, que é a introdução do trabalho. No Capítulo 2, serão apresentados os conceitos básicos sobre para-raios de ZnO, processos estocásticos e modelos de previsão baseados em inteligência artificial.

O Capítulo 3 trata do levantamento do estado da arte das técnicas destinadas para estimar a vida útil de para-raios de ZnO por meio da previsão qualitativa (experiência empírica) ou quantitativa (modelos de regressão ou por séries temporais), com o objetivo de evidenciar a evolução das pesquisas nessa área.

No tocante à metodologia, abordada no Capítulo 4, apresentar-se-ão as suas principais partes, que foram essenciais para realizar previsão de STs, com foco na estimação da vida útil dos para-raios considerados neste trabalho. As principais partes são divididas em: constituição do banco de dados de STs, técnicas utilizadas para previsão de STs e indicadores de desempenho.

No Capítulo 5, serão apresentados os resultados obtidos por meio das técnicas de previsão de STs, que empregam modelos puros e combinacionais baseados em inteligência artificial, para estimação da vida útil de para-raios, bem como análise desses

resultados, por meio da comparação entre o desempenho de cada um dos modelos implementados.

Por fim, o trabalho é finalizado com as conclusões apresentadas no Capítulo 6, com ênfase nas contribuições deste trabalho para as áreas de proteção de equipamentos de alta tensão e gerenciamento de ativos do SEP.

2 FUNDAMENTAÇÃO TEÓRICA


Neste capítulo, serão apresentados os principais conceitos que estão relacionados com o processo de estimação da vida útil de para-raios de ZnO por meio da previsão de STs. Na seção 2.1, apresenta-se a definição de para-raios de ZnO, bem como suas principais características elétricas. Na seção 2.2, define-se o conceito de série temporal e a forma clássica de realizar sua análise. Já na seção 2.3, serão apresentados os principais modelos de previsão abordados na literatura, além de serem julgados como os mais adequados para o desenvolvimento deste trabalho.

2.1 PARA-RAIOS DE ZNO

Existem vários tipos de sobretensões que podem danificar equipamentos elétricos de uma subestação. Os principais tipos de sobretensão são de origem interna (operações de manobra) e externa (descargas atmosféricas), sendo esses tipos de surtos as maiores causas de desligamentos (VIDEIRA, 2011). Ademais, a ocorrência de desligamentos não programados causam distúrbios no suprimento e na oferta de energia, resultando em danos financeiros. Com o intuito de proteger os equipamentos da subestação, geralmente de custo elevado, são instalados equipamentos de proteção que mantenham a qualidade e confiabilidade do sistema, sendo os para-raios os equipamentos mais adequados para esta finalidade (BARGIGIA *et al.*, 1986; GUPTA, 1990).

O termo para-raios data do início do desenvolvimento e da aplicação destes equipamentos de proteção nos SEPs, quando a maior parte das sobretensões era associada aos fenômenos de descargas atmosféricas. Esses dispositivos eram denominados centelhadores, que ainda hoje possuem aplicação específica. Atualmente, existem centelhadores, para-raios com resistores não lineares (com centelhadores) e para-raios apenas com resistores não lineares (FRONTIN, 2013). Os SEPs ainda utilizam, majoritariamente, dois tipos de para-raios, os que são à base de Carboneto de Silício (SiC) e os que são constituídos de varistores de ZnO. A diferença entre esses tipos de para-raios reside no comportamento da curva característica $V - I$ e na presença dos centelhadores nos para-raios de SiC. Na Figura 1, pode-se visualizar a evolução dos para-raios.

Figura 1 – Ilustração da evolução dos para-raios. (a) com centelhador e dielétrico a ar; (b) centelhador em série com blocos não lineares; (c) centelhador com alongador de arco em série com blocos não lineares; (d) formado apenas por resistores não lineares.



Fonte: adaptado de (FRONTIN, 2013).


Os varistores de ZnO surgiram no decênio de 1970 destinados a suportar elevadas tensões nominais dos sistemas elétricos sem a necessidade do uso de centelhadores. Esses tipos de resistores não lineares passaram a ser utilizados na composição de supressores de surtos, representando um grande avanço na proteção dos sistemas elétricos, sendo aplicado inicialmente na proteção de dispositivos eletrônicos (GUPTA, 1990). Com isso, tornou-se possível obter dispositivos mais confiáveis, com coeficiente de não linearidade mais elevado e com capacidade de dissipação de energia duas vezes maior que a promovida pelos varistores de SiC (SAKSHAUG, 1991; HILEMAN, 1999; COSTA, 1999).

Nesse sentido, os para-raios de ZnO vêm sendo empregados na proteção dos equipamentos instalados nos sistemas elétricos contra sobretensões provenientes de operação de manobra e descargas atmosféricas. Esses dispositivos possuem função de limitar o nível de tensão que atingiria equipamentos importantes, tais como os transformadores de potência, prevenindo que os mesmos sejam submetidos a níveis de tensão inadequados à sua operação.

2.1.1 ASPECTOS CONSTRUTIVOS

Os para-raios de ZnO são constituídos, predominantemente, de pastilhas de elementos não lineares, montados dentro de um invólucro de porcelana ou material polimérico; além de outros componentes estruturais (HINRICHSEN, 2012). A configuração desse dispositivo depende do sistema no qual será aplicado. Com relação à sua estrutura, apresenta-se na Figura 2 uma representação de para-raios de ZnO com invólucro de porcelana.

Figura 2 – Representação da estrutura de um para-raios de ZnO com invólucro de porcelana.



Fonte: adaptado de (ABB, 2016).

Dentre vários componentes que constituem o para-raios, os blocos de ZnO são os principais, cujos formatos são normalmente cilíndricos. O diâmetro de cada um deles é definido de acordo com a capacidade de absorção de energia desejada para o equipamento, variando de 30 mm para sistemas de distribuição, até 100 mm ou mais para sistemas de alta ou extra-alta tensão. A altura das pastilhas normalmente varia entre 20 mm e 45 mm dependendo dos métodos de produção utilizados e do grau de homogeneidade dos grãos de ZnO (HINRICHSEN, 2012). Na Figura 3, apresentam-se blocos de varistores de ZnO.

Outro elemento construtivo relevante para o bom funcionamento do para-raios é o invólucro, visto que o mesmo é utilizado para dificultar a infiltração de substâncias e o acúmulo de sujeira proveniente da poluição. Verifica-se que ao longo de todo o comprimento da coluna de porcelana ou polimérica, externamente, são empregadas aletas que possibilitam o escoamento entre os terminais, a fim de reduzir as correntes superficiais externas (LIRA, 2012).

Figura 3 – Varistores de ZnO em diversas dimensões.



Fonte: próprio autor.

2.1.2 CARACTERÍSTICAS ELÉTRICAS


Os para-raios de ZnO possuem como característica principal e desejável a não linearidade em relação à curva $V - I$. Por possuir essa característica, eles são conectados diretamente com o sistema elétrico, gerando apenas uma corrente de fuga na faixa dos microampères, em condições normais de operação. Ademais, a não linearidade atribuído a esses equipamentos de proteção permite que eles se sobressaíam em relação aos para-raios convencionais à base de SiC.

Apresenta-se, na Figura 4, uma curva característica típica de um para-raios de ZnO, na qual são destacadas as principais regiões, bem como os pontos de interesse. A região que o para-raios deve operar em regime permanente consiste na região de baixas correntes, que é destacada no gráfico. Na segunda região da curva $V - I$, também chamada de região de alta não linearidade, o para-raios conduz correntes elevadas, mesmo para pequenas variações de tensão. A terceira região da curva é denominada região de altas correntes, e está diretamente relacionada ao nível de proteção oferecido pelo para-raios contra descargas atmosféricas.

A corrente de fuga total, $i(t)$, que percorre o para-raios de ZnO é composta por uma componente capacitiva, $i_C(t)$, e por uma componente resistiva, $i_R(t)$. A faixa de valores típicos de $i(t)$ encontra-se em torno de poucos miliamperes em condição normal de operação do para-raios e do sistema, enquanto que as componentes capacitiva e resistiva variam de 0,2 a 3,0 mA e de 10 μ A a 600 μ A, respectivamente (LUNDQUIST *et al.*, 1990). Na Figura 5, apresenta-se a forma de onda típica da corrente de fuga de um


para-raios de ZnO, como também é apresentado o sinal da tensão aplicado sobre o dispositivo.

Figura 4 – Curva característica típica do para-raios de ZnO.



Fonte: adaptado de (ABB, 1995).

Figura 5 – Sinais da tensão aplicada e corrente de fuga total de um para-raios de ZnO operando na região de baixas correntes.



Fonte: próprio autor.

2.1.3 PRINCIPAIS PARÂMETROS

Os critérios de escolha e principais parâmetros de um para-raios de ZnO são: Tensão Nominal (NV, do inglês *Nominal Voltage*), Tensão Máxima de Operação Contínua (MCOV, do inglês *Maximum Continuous Operating Voltage*) e capacidade de absorção de energia, cujas definições são apresentadas em (IEC 60099-5, 2013). Essas definições, de forma resumida, são apresentadas a seguir.

- **NV:** máximo valor eficaz de tensão temporária permitida entre os terminais do para-raios para que ele continue funcionando de acordo com suas características de projeto, sem conduzir a um processo de avalanche térmica.
- **MCOV:** maior valor eficaz de tensão à frequência industrial admissível que um para-raios é projetado para operar continuamente.
- **Capacidade de absorção de energia:** quantidade de energia que um para-raios é capaz de absorver e dissipar durante um surto sem alteração de suas características de projeto.

2.1.4 PROPRIEDADES DA CORRENTE DE FUGA

A corrente de fuga total é um ótimo indicador do nível de degradação de para-raios de ZnO, sobretudo sua componente resistiva e o seu conteúdo harmônico. O conhecimento do comportamento desse indicador é imprescindível para constituição da ST que será necessária na estimação da vida útil de para-raios. Considerando isso, apresentar-se-ão as principais propriedades da corrente de fuga do para-raios de ZnO, sendo respeitada a seguinte sequência: propriedades da corrente de fuga, corrente de fuga capacitiva, corrente de fuga resistiva, conteúdo harmônica da corrente de fuga e perda de potência.

1.1.1.1 PROPRIEDADES DA CORRENTE DE FUGA

Por convenção, a corrente de fuga total do para-raios é composta por uma componente resistiva e outra capacitiva. Um modelo elétrico de para-raios para baixas correntes, referente a essa convenção, é apresentado na Figura 6. Verifica-se que esse modelo é composto por uma capacitância em paralelo com uma resistência não linear. A capacitância, C , corresponde à permissividade dos varistores de ZnO e às capacitâncias parasitas, sendo função também da tensão aplicada ao para-raios (IEC 60099-5, 2013;

LUNDQUIST *et al.*, 1990). A característica da curva $V - I$ do para-raios é atribuída à resistência não linear, a qual está relacionada ao processo de condução dos varistores de ZnO. A condução se dá por meio de mudanças na barreira de potencial formada na região intergranular dos varistores. Essa barreira muda de acordo com a intensidade do campo elétrico aplicado e variação da temperatura do varistor (IEC 60099-5, 2013; LUNDQUIST *et al.*, 1990). Desse modo, define-se a corrente de fuga total em (1) e sua componente capacitiva em (2).


$$i(t) = i_c(t) + i_R(t), \quad (1)$$

em que:

$$i_c(t) = C \frac{dv(t)}{dt}, \quad (2)$$

sendo $v(t)$ a tensão aplicado ao para-raios.

Figura 6 – Modelo elétrico simplificado de um para-raios de ZnO.



Fonte: adaptado de (GUPTA, 1990).

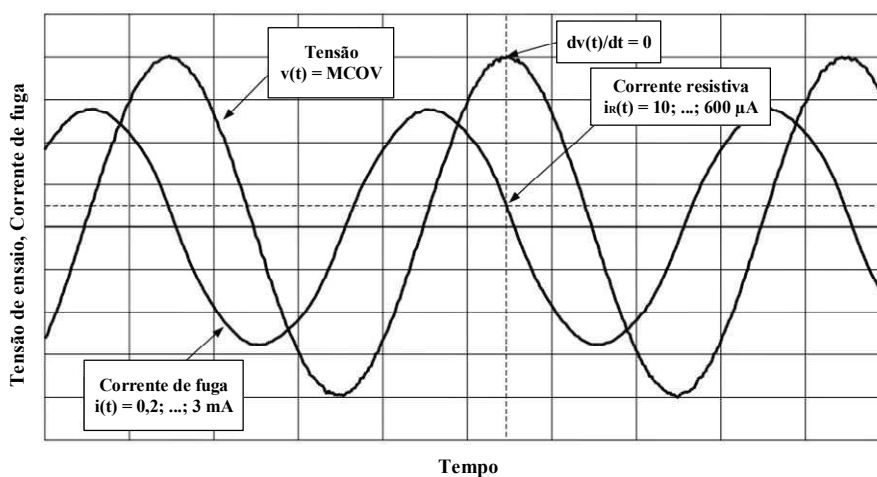
1.1.1.2 CORRENTE DE FUGA CAPACITIVA

A componente capacitiva da corrente é predominante na constituição da corrente de fuga total que percorre o para-raios de ZnO. A principal causa dela é a existência da permissividade dos resistores não lineares e capacitâncias parasitas. Estudos indicam que a corrente de fuga capacitiva não mudaria significativamente devido à deterioração dos resistores não lineares (IEC 60099-5, 2013). Assim, adotar a componente capacitiva da corrente de fuga como indicador do nível de degradação do para-raios não seria seguro e confiável.

1.1.1.3 CORRENTE DE FUGA RESISTIVA

A corrente de fuga resistiva é caracterizada por ser um sensível indicador de mudanças na curva característica $V - I$ dos resistores não lineares. É tanto que um elevado nível de corrente de fuga resistiva pode conduzir o para-raios para um estado de instabilidade térmica resultado na falha completa do dispositivo (UDDINA, 2015). Desse modo, essa componente pode ser utilizada como um indicador do nível de degradação de para-raios. Para um sinal de tensão puramente senoidal, a corrente de fuga resistiva é definida como o nível da corrente de fuga no instante que a tensão é máxima ($dv/dt = 0$) (HINRICHSEN, 1997), conforme sugerido na Figura 7.

Figura 7 – Corrente de fuga típica de um para-raios de ZnO sob condições controladas.




Fonte: adaptado de (IEC 60099-5, 2013).

1.1.1.4 CONTEÚDO HARMÔNICO DA CORRENTE DE FUGA

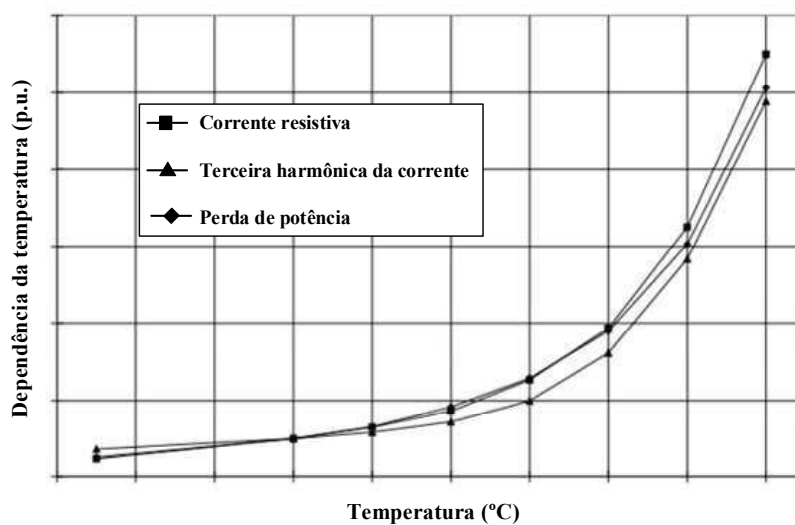
As componentes harmônicas presentes na corrente de fuga dos para-raios de ZnO são provenientes das características dos resistores não lineares quando o para-raios é energizado com tensão de natureza de Corrente Alternada (AC, do inglês *Alternating Current*). A magnitude da corrente resistiva e o grau de não linearidade dos blocos influenciam o conteúdo harmônico da corrente (ENDO *et al.*, 1988; TRIDELTA, 2007; HINRICHSEN, 1997; IEC 60099-5, 2013). É importante observar ainda que o conteúdo harmônico depende da tensão e temperatura, sobretudo a terceira componente harmônica da corrente de fuga total, I_{t3} . Apresentam-se, nas Figuras 8 e 9, ilustrações dessas dependências.

Figura 8 – Comportamento relativo da componente resistiva, da componente harmônica de 3ª ordem da corrente de fuga total e da perda de potência em função da relação entre a tensão aplicada ao para-raios e a tensão de operação contínua.



Fonte: adaptado de (IEC 60099-5, 2013).

Figura 9 – Comportamento relativo da componente resistiva, da componente harmônica de 3ª ordem da corrente de fuga total e da perda de potência em função da temperatura.



Fonte: adaptado de (IEC 60099-5, 2013).

Tendo em vista a semelhança do comportamento da terceira componente harmônica da corrente de fuga com relação à componente resistiva em função da tensão aplicado sobre o para-raios, como também da temperatura, constata-se que I_{t3} é um ótimo indicador do nível de degradação de para-raios, já que $i_R(t)$ está relacionada às perdas de potência ativa. Essa semelhança é justificada pelo fato de que I_{t3} possui valores típicos da ordem de 10 a 40% da componente resistiva da corrente de fuga (ABB, 2010). E, ainda, como forma de utilizar esse indicador para evitar falhas não programáveis, recomenda-se

a retirada do para-raios de serviço, caso o valor de I_{t3} ultrapasse 0,1 mA (100 μ A) (TRIDELTA, 2007).

1.1.1.5 PERDA DE POTÊNCIA


Além da corrente de fuga total, sua componente resistiva e seu conteúdo harmônico, um indicador do nível de degradação do para-raios de ZnO é a perda de potência. Os valores típicos de perda de potência vão de 5 mW/kV até 300 mW/kV na tensão de MCOV e 20 °C (IEC 60099-5, 2013). A perda de potência pode variar em função da tensão e temperatura, como apresentado nas Figuras 8 e 9.

2.2 SÉRIES TEMPORAIS

Em diversas áreas, tais como estatística, matemática aplicada e processamento de sinais, uma ST consiste em um conjunto de observações de um fenômeno ou variável qualquer feitas sequencialmente ao longo do tempo (MORETTIN & TOLOI, 1981). O aspecto mais relevante das STs reside no fato das observações vizinhas serem dependentes (EHLERS, 2009). Para o estudo dessa coleção de dados, utilizam-se conceitos e modelos probabilísticos para analisar e modelar essa dependência (XAVIER, 2018). A título de exemplo, apresenta-se na Figura 9 a ST da terceira componente harmônica da corrente de fuga de um para-raios de ZnO tipo estação, de janeiro de 1995 até janeiro de 2015.

Ainda com relação à definição da ST, ela pode ser compreendida como resultado de um processo estocástico, isto é, uma observação, dentre infinitas possíveis, de um ensaio aleatório. Considerando isso, o fenômeno que causou a ST é modelado por uma distribuição de probabilidade, da qual se deseja conhecer as propriedades que a define. No tocante à classificação das STs, é possível classificá-las em discretas e contínuas. Considera-se a ST discreta quando as observações são realizadas em instantes de tempo específicos, que, comumente, estão espaçadas em intervalos de tempo constantes, por um determinado período. Como as observações da ST apresentada na Figura 9 são realizadas mensalmente, classifica-a como discreta. A ST contínua é caracterizada pelas observações serem realizadas ininterruptamente (MORETTIN & TOLOI, 1981).

Figura 10 – Comportamento da ST ao longo de 21 anos (252 meses), desde 1995 até 2015.



Fonte: próprio autor.

A finalidade principal, dentre outras, da análise do comportamento da ST é identificação de um modelo que se ajuste aos dados analisados (MORETTIN & TOLOI, 1981). Uma vez que o modelo se adequa aos dados constituintes da ST, pode-se utilizá-lo para realizar previsões. Para realizar essa análise, geralmente ela é feita no domínio do tempo (análise temporal) e/ou no domínio da frequência (análise espectral). A análise temporal possui o intuito de observar a magnitude do fenômeno que ocorre em determinado instante e na relação entre as observações. Essa análise geralmente é realizada pela Função de Autocorrelação (FAC). Já a análise no domínio da frequência, a identificação da frequência para determinado evento é o interesse dessa análise espectral, sendo comumente aplicado a transformada de Fourier como ferramenta para auxiliar na análise.

A escolha do tipo de análise depende da problemática a ser resolvida. A análise espectral é destinada para problemas com características determinísticas, enquanto que a análise temporal é voltada para processos não determinísticos. Apesar disso, essas formas de análise, em vez de serem excludentes, são consideradas complementares (BALINNI, 2000).

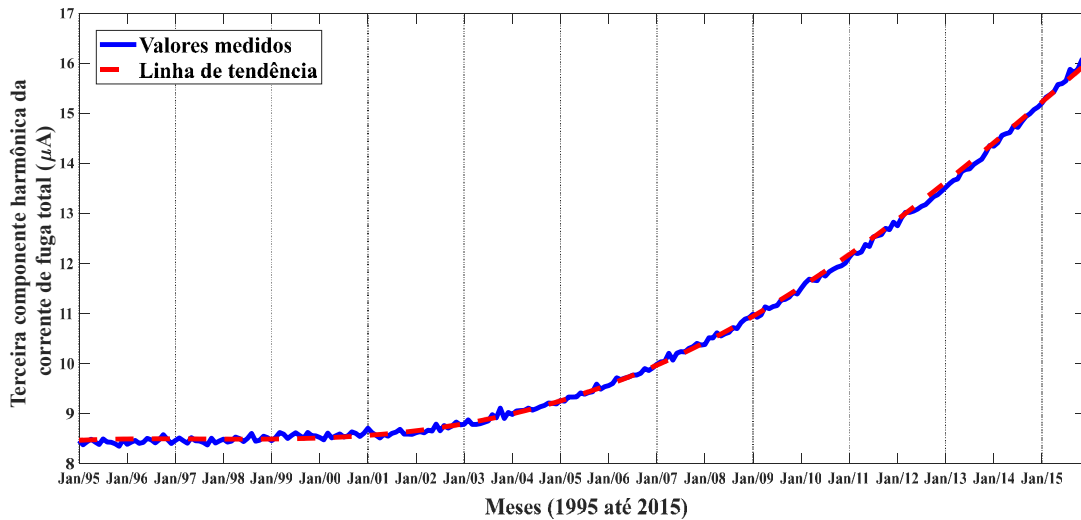
A forma clássica de análise de STs reside, resumidamente, em decompor a série em três componentes, denominadas de: tendência, sazonal e aleatória. A definição matemática que representa a ST, considerando a análise clássica, é expressa em (3). Com relação a cada uma dessas componentes, a tendência é a componente da série que descreve seu comportamento crescente ou decrescente. A determinação dessa componente é dada por meio do ajuste dos dados da ST em função do tempo, que pode ser linear, polinomial,

exponencial ou outra função suave do tempo (MORETTIN & TOLOI, 1981). Apresenta-se, na Figura 11, a série da componente harmônica de terceira ordem da corrente de fuga total com sua linha de tendência exponencial.

$$Y_t = T_t + S_t + a_t, \quad (3)$$

em que T_t é a componente de tendência, S_t é a componente sazonal e a_t é a componente aleatória.

Figura 11 – Componente de tendência da ST analisada neste trabalho, com valores da terceira componente harmônica da corrente de fuga total.



Fonte: próprio autor.

Outra componente importante na constituição da ST é a componente sazonal. Essa componente descreve a característica periódica da série. Para determinação dessa componente, utiliza-se (4), dado que a série possui período $N = 2q + 1$, se N for ímpar, ou $N = 2q$, se N for par, e o número de observações da série é dado por n .


$$S_k = w_k - \frac{1}{N} \sum_{i=1}^N w_i, \quad k = 1, \dots, N, \quad (4)$$

em que, para cada k , w_k é a média dos desvios, calculados por meio de (5).

$$Y_{k+jN} - T_{k+jN}, \quad q < k + jN \leq n - q, \quad (5)$$

sabendo que para qualquer $k > N$, é obtido $S_k = S_{k-N}$. Desse modo, determina-se a componente sazonal da ST da terceira componente harmônica da corrente de fuga, a qual apresenta periodicidade de 12 meses ($N = 12$), de acordo com a Figura 12.


Figura 12 – Componente sazonal da ST considerada neste trabalho, constituída por valores da terceira componente harmônica da corrente de fuga total.



Fonte: próprio autor.

No tocante à componente aleatória, a_t , sua determinação é realizada por meio da subtração entre as componentes T_t e S_t da série original. Devido à característica aleatória de a_t , supõe-se que ela seja um processo estocástico, com média zero e variância constante (MORETTIN & TOLOI, 1981). Com a finalidade de analisar a componente da ST considerada neste trabalho, apresenta-se, na Figura 13, sua representação.

Figura 13 – Componente aleatória da ST considerada neste trabalho, constituída por valores da terceira componente harmônica da corrente de fuga total.



Fonte: próprio autor.

Como a maioria das técnicas de análise estatística de STs supõem que elas sejam estacionárias (MORETTIN & TOLOI, 1981), faz-se necessário a remoção das

componentes de tendência e sazonalidade com relação à ST original, a fim de que a série se torne estacionária. Uma forma geralmente adotada na literatura para realizar isso consiste em diferenciar a série sucessivamente até que se torne estacionária. Em primeiro lugar, utiliza-se o operador diferença, o qual é definido em (6).

$$\nabla Y_t = Y_t - Y_{t-1} = (1 - B)Y_t, \quad (6)$$

em que ∇ é denominado de operador diferença e B é o operador atraso. Nesse sentido, a k -ésima diferença é dada por (7). Já para $k = 1$, é obtido (8).

$$\nabla^k Y_t = \nabla(\nabla^{k-1} Y_t) = (1 - B)^k Y_t, \quad (7)$$

$$\begin{aligned} \nabla^2 Y_t &= \nabla(\nabla^{2-1} Y_t) = \nabla(\nabla Y_t) = (1 - B)(1 - B)Y_t = (1 - 2B + B^2)Y_t \\ &= Y_t - 2Y_{t-1} + Y_{t-2}. \end{aligned} \quad (8)$$

A título de informação, para uma série não sazonal, realizar a primeira e a segunda diferença, normalmente, é suficiente para que a série se torna estacionária (MORETTIN & TOLOI, 1981). Isso ocorre, em virtude de que muitas séries podem possuir o comportamento semelhante a uma função polinomial, cujo grau é aceitavelmente baixo (BROCKWELL, 2002).

Para uma ST sazonal de período N , deve-se aplicar à série o operador diferença de atraso N , ∇_N , que é definido em (9). Com aplicação do operador ao modelo definido em (3), obtém-se (10). E, ainda, como $S_t = S_{t-N}$, é obtido (11). Tendo em vista que a série $\nabla_N Y_t$ possui ainda a componente de tendência, para removê-la é aplicado o operador diferença, conforme foi empregado em (6) e (7).

$$\nabla_N Y_t = Y_t - Y_{t-N}, \quad (9)$$

$$\nabla_N Y_t = T_t - T_{t-N} + S_t - S_{t-N} + a_t - a_{t-N}, \quad (10)$$

$$\nabla_N Y_t = T_t - T_{t-N} + a_t - a_{t-N}. \quad (11)$$

2.3 CONCEITOS BÁSICOS DE PROCESSOS ESTOCÁSTICOS

Do ponto de vista conceitual, processo estocástico é uma coleção de variáveis aleatórias que, geralmente, são empregadas para estudar a evolução de fenômenos (ou sistemas) que são observados ao longo do tempo (BHAT, 1972). Matematicamente, um processo estocástico é definido como uma família $Y = \{Y_t, t \in T\}$, tal que para cada $t \in T$, Y_t é uma variável aleatória. Se a série for discreta, o conjunto T pode ser o conjunto dos números inteiros positivos, \mathbb{Z}_+ ; já se a série for contínua, o conjunto T pode ser o conjunto dos números reais, \mathbb{R}_+ . Em termos práticos, considerando a análise de STs, não é possível fazer mais do que uma observação em cada tempo t (EHLERS, 2009). Assim,

o processo estocástico ocorre uma única vez, de modo que seja possível fazer apenas uma observação da variável aleatória Y_t .

2.3.1 ESTACIONARIEDADE

O conceito de estacionariedade possui grande relevância na análise de STs. Um processo estocástico deve ser considerado estacionário caso suas propriedades estatísticas não se alterem no tempo, ao passo que a seleção de uma origem para o tempo não é relevante (BALLINI, 2000; MORETTIN & TOLOI, 1981). Isto é, as características de $Y_{t+\tau}$, para todo τ , são as mesmas de Y_t . No tocante aos tipos de estacionariedade, existe a estacionariedade estrita (ou forte), bem como o tipo fraca (também denominado de ampla ou de segunda ordem).

Um processo estocástico é classificado como estritamente estacionário se a probabilidade conjunta associada a n observações $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ é a mesma que associada a n observações $Y_{t_1+\tau}, Y_{t_2+\tau}, \dots, Y_{t_n+\tau}$, para quaisquer τ e $n \geq 1$. Isto é, ao ser realizado um deslocamento no tempo de τ em relação à origem, não há efeito sobre a distribuição de probabilidade conjunta (EHLERS, 2009). Isso possibilita que todas as distribuições unidimensionais, $n = 1$, sejam invariantes no tempo. Dessa forma, o valor esperado, $\mu_t = E(Y_t)$, e a variância, $\sigma_t^2 = E[(Y_t - \mu_t)^2]$, são constantes para todo $t \in T$, conforme expresso em (12) e (13).

$$\mu_t = \mu, \quad (12)$$

$$\sigma_t^2 = \sigma^2. \quad (13)$$

Já o processo estocástico é considerado estacionário no sentido amplo ou fracamente estacionário caso $\mu_t = E(Y_t) = \mu$ seja constante para todo $t \in T$. E a condição que deve ser satisfeita é que $\gamma(t_1, t_2) = Cov(Y_{t_1}, Y_{t_2})$ seja uma função que só depende de $t_2 - t_1$.

2.3.2 FUNÇÕES DE AUTOCOVARIÂNCIA E AUTOCORRELAÇÃO

No tocante ao conceito de autocovariância, considera-se uma série estacionária com valor esperado μ . Considerando isso, a covariância entre uma observação Y_t e outra observação Y_{t+h} é chamada de autocovariância no atraso h , cuja definição é expressa em (14). O conjunto dos valores de γ_h em função de h , para $h = 0, 1, 2, \dots$, é denominado de função de autocovariância. A autocovariância no atraso $h = 0$ é a variância da ST.

$$\rho_h = \frac{Cov(Y_t, Y_{t+h})}{Var(Y_t)} = \frac{\gamma_h}{\gamma_0}. \quad (14)$$

A FAC consiste no conjunto de valores do coeficiente de autocorrelação ρ_h , para $h = 0, 1, 2, \dots$, cuja definição desse coeficiente é dado em (15). A partir da definição desse coeficiente, verifica-se que a função de autocorrelação é adimensional, isto é, não depende da escala de medida da ST. E ainda é constatado que $\rho_0 = 1$. Assim, para uma ST estacionária com n observações, tais como Y_t, Y_{t+1}, \dots, Y_n , a FAC amostral é definida em (15).

$$r_h = \frac{c_h}{c_0}, \quad h = 0, 1, 2, \dots, n-1, \quad (15)$$

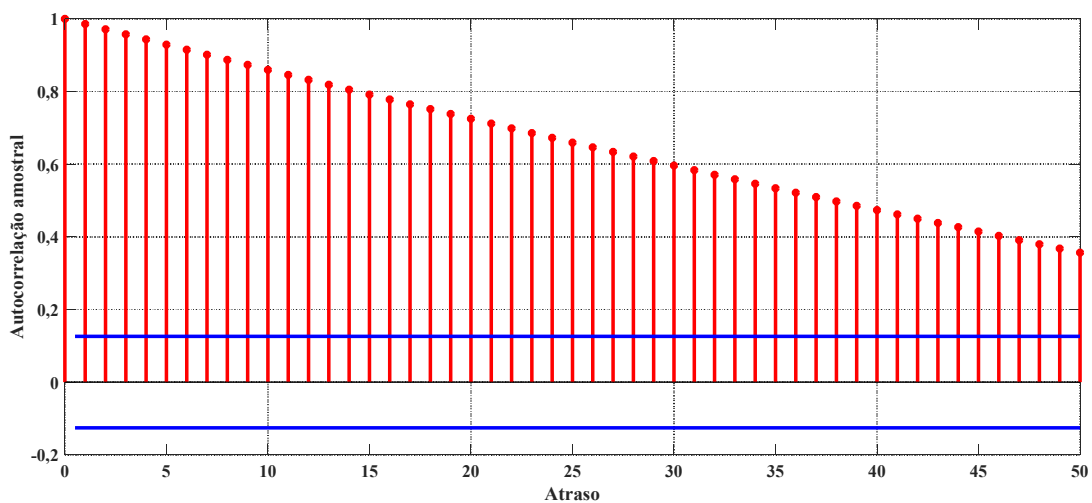
sabendo que c_h é expresso em (16).

$$c_h = \frac{1}{n} \sum_{t=1}^{n-h} (Y_t - \bar{Y})(Y_{t+h} - \bar{Y}), \quad h = 0, 1, 2, \dots, n-1, \quad (16)$$

em que c_h é a estimativa do coeficiente de autocovariância, γ_h , e \bar{Y} é a média aritmética das observações.

Tendo em vista as propriedades da FAC, ela torna-se uma relevante ferramenta na análise de STs, sobretudo com relação à sua estacionariedade. Segundo Montgomery *et al.* (2008), uma FAC com decaimento lento sugere desvios da estacionariedade. Considerando isso, uma ST estacionária deve apresentar uma FAC com decaimento rápido. Com o intuito de analisar a FAC da ST considerada neste trabalho, apresenta-se, na Figura 14, a FAC amostral da ST de valores da terceira componente harmônica da corrente de fuga total. A partir dessa figura, constata-se que a ST não é estacionária, haja vista o comportamento da FAC.

Figura 14 – Gráfico da FAC para constatar o decaimento lento.



Fonte: próprio autor.

2.4 MODELOS DE PREVISÃO DE SÉRIES TEMPORAIS

A modelagem de STs possui como intuito principal descrever o comportamento da série e realizar previsões do seu comportamento, buscando minimizar os erros entre os valores estimados e os dados observados. Apesar dessa busca pelas melhores previsões possíveis, um modelo que descreve uma série não conduz, necessariamente, a um processo de previsão, uma vez que é necessário especificar uma função perda (e.g., erro percentual absoluto médio), além do modelo (MORETTIN & TOLOI, 1981).

De modo geral, os modelos de previsão são classificados em qualitativos e quantitativos. E, ainda, os quantitativos são subdivididos em modelos univariáveis (ou STs) e modelos multivariáveis. Ademais, existem os modelos baseados em inteligência artificial, os quais não se enquadram na classificação de modelos univariáveis ou multivariáveis (MORETTIN & TOLOI, 1981; HONG, 2018).

Os modelos de previsão classificados como qualitativos caracterizam-se por serem subjetivos, baseados na intuição e experiência do analista ou cientista que esteja realizando a previsão. E, ainda, esses modelos podem ser baseados em opiniões pessoais (SCHWITZKY, 2001). Eles são especialmente úteis quando não se dispõe de dados históricos, ou quando os dados existentes são insuficientes para realizar previsões (LURGIO, 1998). Assim, os modelos qualitativos, geralmente, são úteis para darem suporte aos modelos quantitativos.

No tocante aos modelos de previsão quantitativos, sabe-se que eles são baseados em modelos matemáticos, os que requerem, para realizar previsão, o emprego de dados históricos. Por ter o caráter matemático, esses tipos de modelos tornam-se menos ambíguos e subjetivos, de modo a proporcionar estimações mais exatas e, conseqüentemente, mais vantagens para o estudo em questão. Com relação ao funcionamento, em tese, o modelo resume formalmente os padrões inerentes aos dados e expressa uma relação estatística entre os valores anteriores e atuais da ST. Uma vez isso realizado, utiliza-se o modelo para projetar os padrões dos dados no futuro. Considerando os modelos quantitativos existentes, os mais empregados são (MONTGOMERY *et al.*, 2008): Suavização Exponencial Simples; Autoregressivo Integrado de Médias Móveis (ARIMA, do inglês *Autoregressive Integrated Moving Average*); Autoregressivo de Médias Móveis (ARMA, do inglês *Autoregressive Moving Average*), Média Móvel (MA,

do inglês *Moving Average*) e Autoregressivo (AR, do inglês *Autoregressive*) univariáveis; e Gray.

Com relação aos modelos que não são classificados como qualitativos e quantitativos, eles se baseiam, geralmente, no emprego de inteligência artificial para realizar previsões do comportamento de STs. Dentre esses modelos, os mais empregados são (HONG, 2018): Rede Neural Artificial (ANN, do inglês *Artificial Neural Networking*), Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*), Sistema Neuro-Fuzzy (NFS, do inglês *Neuro-Fuzzy System*), Memória Longa de Curto Prazo (LSTM, do inglês *Long Short-Term Memory*) e Algoritmo Genético (GA, do inglês *Genetic Algorithm*).

Os modelos de previsão citados anteriormente possuem vantagens e desvantagens, a depender da problemática que se pretende resolver. Tendo em vista a Tabela 1, é possível constatar as vantagens e desvantagens dos modelos de previsão, de forma resumida. A partir dessa tabela, torna-se possível selecionar os modelos que são mais adequados para serem utilizados na previsão de STs com comportamento não linear e que não apresenta estacionariedade, considerando os modelos quantitativos e os que se baseiam no emprego de inteligência artificial. Com base na Tabela 1 e diversos trabalhos apresentados na literatura (MONTGOMERY *et al.*, 2008; HONG, 2018), verifica-se que os modelos quantitativos, sobretudo os que se baseiam em estatística, são destinados para uma base de dados linear e STs estacionárias. Já os modelos baseados em inteligência artificial são mais adequados para trabalhar com a não linearidade, como também com a não estacionariedade das amostras de STs utilizadas.

Tabela 1 – Vantagens e desvantagens dos modelos de previsão quantitativos.

Modelos	Vantagens	Desvantagens
Suavização exponencial simples	- Fácil entendimento; - Maior custo-benefício dentre os métodos de extrapolação.	- Não pode ser aplicado a séries não estacionárias.
ARIMA	- Modelos flexíveis; - Pode ser usado para prever séries temporais.	- Requer conhecimento profundo de técnicas estatísticas; - Assume uma relação linear entre a variável dependente e independente.
ARMA, MA e AR univariados	- Apresentam melhor acurácia na previsão quando comparados com o método de suavização exponencial.	- Necessidade de conhecimento estatístico prévio; - Não pode prever séries não estacionárias;

		- Supõe relação linear entre a variável explicativa e a variável a ser prevista.
Gray	- Possibilita a previsão a partir de uma amostra de dados pequena.	- Representa apenas um processo monotonamente crescente ou decrescente.
SVM	- Excelente capacidade de generalização na situação de pequena amostra de dados; - Capacidade de trabalhar com dados não lineares.	- Dificuldade na escolha da função <i>kernel</i> .
NFS	- Melhor desempenho do que as ANNs diante de presença de ruídos nos dados; - Capacidade de autoaprendizagem e autodirecionamento; - Capacidade de trabalhar com dados não lineares.	- Trabalha com número reduzido de entradas, devido ao problema de explosão combinatória de regras.
LSTM	- Informação contextual; - Reconhecimento de longas cadeias de sequências; - Capacidade de trabalhar com dados não lineares.	- Falha para encontrar as dependências de longo prazo; - Alcance das informações são limitados (problema da dissipação do gradiente).
RNA	- Não exige análise prévia da série temporal; - Capacidade de trabalhar com dados não lineares.	- Necessita de uma grande quantidade de dados de treinamento; - Dificuldade de interpretar o modelo.
AG	- Aplicáveis a uma grande variedade de problemas; - Ótimos mecanismos de otimização na previsão.	- Possibilidade de configurações que podem complicar a resolução do problema tratado.
Modelos multivariados	- Capacidade de obter uma visão mais realista do problema quando comparado a modelos univariados.	- Exige um programa estatístico para analisar os dados; - Precisa de uma grande amostra de dados.

Fonte: adaptado de (DIAS & LIRA, 2019).

Apresentar-se-ão, a seguir, os principais modelos aplicados na previsão de STs, considerando os modelos baseados no emprego de inteligência artificial, os quais vêm sendo amplamente utilizados na literatura. Os modelos que serão apresentados consistem nos seguintes, tendo em vista as vantagens apresentadas na Tabela 1: SVM, NFS e LSMT.

2.4.1 SVM

As SVMs são modelos de aprendizado de máquina baseados na teoria de aprendizagem estatística (VANPNIK, 2013). O objetivo da SVM é construir um

hiperplano para separar duas classes de padrões, maximizando a margem de separação entre as classes (HAYKIN, 1998). Como esse tipo de inteligência artificial é baseado em aprendizagem estatística, faz-se necessário a implementação do método de minimização estrutural de risco, que possui a finalidade de escolher um classificador com bom desempenho nos conjuntos de treinamento e teste. Ou seja, é capaz de classificar os exemplos de treinamento da forma mais correta possível, contudo sem focar apenas no exemplo individual, com o intuito de manter a capacidade de generalização do classificador (HAYKIN, 1998; VANPNIK, 1995). Assim, atribuem-se as seguintes vantagens para a SVM: alta capacidade de generalização, robustez para categorização de dados e teorias bem fundamentadas nas áreas de matemática e estatística.

No tocante aos problemas que envolvem regressão não linear, sobretudo para STs, emprega-se a SVM adaptada, passando a ser denominada de Máquina de Vetor de Suporte para Regressão (SVR, do inglês *Support Vector Regression*). O funcionamento de uma SVR, aplicada a uma ST, visa encontrar uma função $f(x)$ que pode ser um desvio menor ou igual a ε . Isto é, o erro máximo entre a resposta obtida pela SVR e a resposta desejada é ε , considerando os exemplos de treinamento (SMOLA, SCH, SCHOLKOPF, 2004). Além de possibilitar a determinação do erro máximo, outra finalidade da SVR é encontrar a função mais plana possível. Como forma de otimizar os resultados obtidos pela SVMs e SVRs, algumas amostras de treinamento são criteriosamente escolhidas para serem denominadas de vetores de suporte, as quais se situam na região de fronteira em duas classes. Para que esses vetores sejam separados de forma ótima, constrói-se um hiperplano, para que todos os dados sejam separados de forma ótima, também. Apresenta-se na Figura 15 um exemplo de hiperplano com separação ótima.

Tendo em vista a possibilidade de não existir uma função que limite os erros em ε no conjunto de treinamento, criou-se a versão da SVR com margens suaves. Para solução dessa problemática, foram incluídas as variáveis de folga ξ^- e ξ^+ , que medem o custo dos erros de previsão para menos e para mais. Dessa forma, o intuito da SVR é encontrar um vetor de pesos w e um limiar b que minimize a função apresentada em (17), sabendo que b é denominada de bias e as restrições impostas em (18), (19) e (20) devem ser consideradas.


$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i^- + \xi_i^+, \quad (17)$$

$$y_1 - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i^-, \quad (18)$$

$$\langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^+, \quad (19)$$

$$\xi_i^-, \xi_i^+ \geq 0. \quad (20)$$

Figura 15 – Hiperplano de separação ótima e seus hiperplanos de suporte.



Fonte: adaptado de (PARMEZAN, 2016).


Considerando (18) e (19), $\langle w, x_i \rangle$ representa o produto interno no espaço do vetor de pesos w . A constante C , que deve ser maior que zero, determina a troca entre a complexidade da função (quanto mais complexa, menos plana) e os desvios tolerados podem ser maiores que ε . Quanto maior for o valor de C , mais complexa é a função, e quanto menor for o valor de C , mais suave é a função. Para o tipo de problema apresentado, apresenta-se na Figura 16 o modelo de SVR correspondente.

Para melhorar o processo de classificação e regressão, as SVMs e SVRs realizam o mapeamento (processo de transformação) do espaço de característica original para um espaço com dimensão superior. Isso é realizado com base no teorema de Cover¹, já que um padrão não linearmente separável tem uma alta probabilidade de ser linearmente separável em uma dimensão maior, contanto que a transformação para novo espaço seja não linear e que a dimensionalidade dele seja suficientemente grande, conforme proposto em (HAYKIN, 1998). Para realizar essa transformação do espaço de estados de entrada

¹ O teorema de Cover afirma que, dado um conjunto de dados para treinamento que não é linearmente separável, é possível transformá-lo em um conjunto de treinamento que é separável linearmente, projetando-o em um espaço de maior dimensão por meio de alguma transformação não linear (COVER, 1965).


para um espaço de características com maior dimensionalidade, aplica-se o procedimento de *kernel*, o qual permite o cálculo dos dados em dimensões maiores sem precisar calcular suas coordenadas nessa dimensão. Apresenta-se na Figura 17 o emprego do procedimento de *kernel* em um espaço de características

Figura 16 – Ilustração do modelo da SVR, considerando as variáveis de folga, vetores de suporte e o hiperplano.



Fonte: adaptado de (SMOLA, SCH, SCHOLKOPF, 2004).

Figura 17 – Aplicação do procedimento de *kernel* em um espaço de características.



Fonte: próprio autor.

Para proceder com o procedimento de *kernel*, computa-se o produto interno entre as imagens dos pares de dados no espaço de características, empregando uma função de *kernel*, que deverá seguir as condições impostas pelo teorema de Mercer² para que seja

² O teorema de Mercer é empregado para validar o emprego de uma determinada função, tal como a função *kernel*. A aplicação desse teorema é bastante vasta, sobretudo na teoria da aproximação. As condições impostas para o emprego desse teorema são apresentadas em (MERCER, 1909).

uma função válida (VAPNIK, GOLOWICH, SMOLA, 1996; HAYKIN, 1998). O emprego dessas funções nas SVMs e SVRs reside em trocar os produtos internos das equações descritas pela função de *kernel*, conforme explicitado em (17), (18) e (19), pela função de *kernel* desejada. Desse modo, o hiperplano ótimo de separação linear para o espaço de características é construído sem precisar considerar o próprio espaço de características (HAYKIN, 1998). Isto é, dispensa-se o cálculo do hiperplano em um espaço com dimensionalidade maior que a dimensionalidade original do problema em questão. A função de *kernel* é definida em (21). Para cada tipo de problema há uma função de *kernel* apropriada, tais como as funções lineares, polinomiais, as de base radial (ou gaussianas) e as sigmoidais.

$$k(x, x_i) = \exp\left(-\frac{1}{2\sigma^2}|x - x_i|^2\right). \quad (21)$$

A função de *kernel* apresentada em (21) é classificada como função de base radial (RBF, do inglês *Radial Basis Function*). Nesse tipo de função, o parâmetro σ é especificado pelo usuário, que é responsável por determinar a largura dos núcleos das funções de base radial. Essa função é amplamente empregada na análise de STs, pois é flexível o suficiente para identificar as variações que ocorrem nas STs avaliadas.

2.4.2 NFS

Os NFSs combinam a capacidade de aprendizado das ANNs com o poder de interpretação linguística da lógica *fuzzy*, já que é um sistema *fuzzy* treinado por um algoritmo proveniente da teoria das redes neurais (JANG, 1993). Com essa união, é possível obter a capacidade de reconhecimento e classificação das redes neurais, considerando a robustez e habilidade de generalização. Além disso, devido às regras e conjuntos provenientes do sistema *fuzzy*, essas peculiaridades auxiliam no entendimento do problema, uma vez que modela o ambiente por meio de uma linguagem próxima da usada pelos especialistas.

O princípio utilizado pelas redes neurais é baseado no funcionamento das redes neurais cerebrais (LUDWIG JÚNIOR & MONTGOMERY, 2007). Sabe-se que o cérebro humano é capaz de representar e armazenar o conhecimento de forma acessível, haja vista sua natureza paralela de funcionamento. Alguns princípios e propriedades do funcionamento do cérebro são aplicados na computação neural, tais como: aprendizagem, generalização e abstração de informações relevantes. E, ainda, é importante frisar que o

conhecimento adquirido pelo processo de treinamento de uma rede neural é empregado a posteriori.

Tendo em vista o exposto, as ANNs são definidas como um conjunto de camadas de neurônios, em que cada neurônio representa a unidade básica de processamento. Os neurônios são interconectados, que, por possuírem essa característica, definem a estrutura da rede. Com relação ao processo de aprendizagem da rede, define-se isso por meio do algoritmo de treinamento. Nesse processo, após um conjunto de padrões de entrada ser apresentado à rede, uma nova informação é obtida e modificações são realizadas nos parâmetros da rede, com a finalidade de que o modelo represente o conhecimento acerca do conjunto de dados apresentado, de modo que respostas adequadas sejam disponibilizadas pela rede para solução da problemática em questão (LUDWIG JÚNIOR & MONTGOMERY, 2007).

No tocante à lógica *fuzzy*, ela é caracterizada por realizar cálculos matemáticos que converte e processa o conhecimento subjetivo de um especialista (ZADEH, 1965). Sabe-se que os seres humanos, em geral, adotam decisões com margem para erro, isto é, não são totalmente verdadeiras. Assim sendo, a lógica *fuzzy* se baseia nessa capacidade, na qual o indivíduo obtém conclusões e respostas por meio de informações vagas, ambíguas, qualitativamente incompletas e imprecisas.

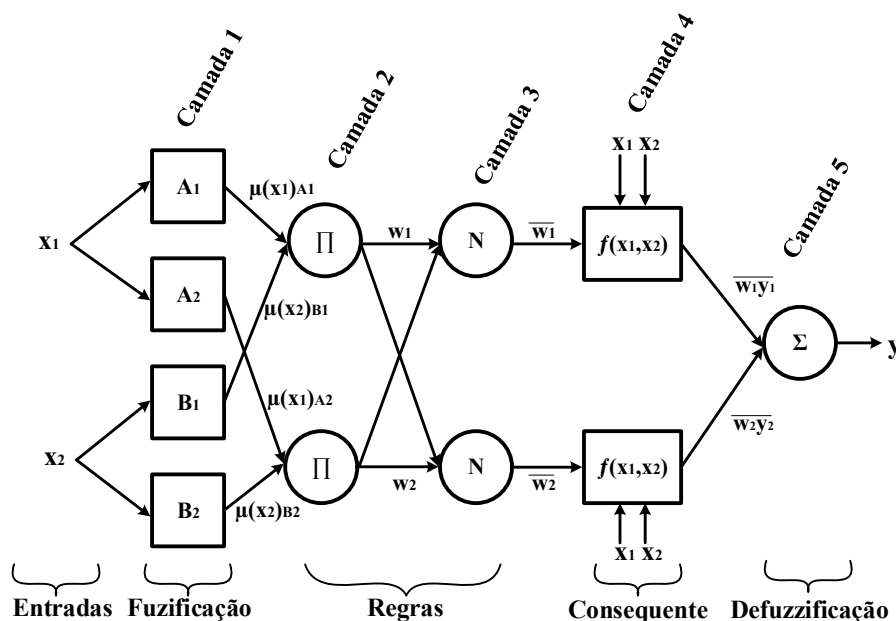
Tendo em vista as principais características apresentadas das ANNs e da lógica *fuzzy*, a união delas, que caracteriza o NFS, possui o intuito de atenuar a deficiência de cada um desses sistemas a fim de se obter um sistema mais eficiente, robusto e de fácil entendimento. Ademais, os NFSs realizam classificação e agrupamento em *clusters*, que, por meio das regras *fuzzy*, relacionam as entradas e saídas. Com relação à aplicação, eles são utilizados para previsão de STs, análise de risco, dentre outros problemas que exigem tomada de decisão. Dentre as estruturas da NFS, a estrutura mais adequada para previsão de STs é o Sistema de Inferência Neuro-fuzzy Adaptativo (ANFIS, do inglês *Adaptive-Neuro-Network-Based Fuzzy Inference System*) (JANG, 1993).

O modelo ANFIS, proposto em (JANG, 1993), é treinado como uma rede neural e operada verossímil a um sistema de inferência *fuzzy*. Nesse sentido, as funções de pertinência são geradas automaticamente por meio do aprendizado neuro-adaptativo e, ainda, são ajustadas utilizando algoritmo de retropropagação sozinho ou combinado com o método dos mínimos quadrados. Assim, o sistema aprende com o modelo.

Os ANFISs possuem uma arquitetura em rede similar a arquitetura das ANNs, que mapeiam um conjunto de entradas em uma saída. Esse mapeamento ocorre por meio de

uma série de cinco camadas, conforme apresentado na Figura 18. A primeira camada é destinada para as variáveis de entrada, que são normalizadas e escalonadas dentro de um intervalo numérico, com a possibilidade deste ser $[0,1]$ ou $[-1,1]$. Já na segunda camada, ocorre o processo de fuzzificação, no qual os intervalos das variáveis de entrada são divididos em diversos níveis, que indicam os pesos da rede para cada entrada. Na terceira camada encontram-se as regras geradas pela lógica *fuzzy*, desenvolvido por Takagi-Sugeno (MOZELLI, 2008). A quarta camada é determinada pelos consequentes das regras. Por fim, a quinta camada é voltada para o processo de defuzzificação, no qual é calculado o valor numérico de saída.

Figura 18 – Arquitetura ANFIS.



Fonte: adaptado de (SANCHEZ, 2009).

A título de exemplificação, com base na Figura 18, consideram-se duas entradas x_1 e x_2 e uma saída y . No contexto de previsão de STs, as variáveis x_1 e x_2 correspondem a grandeza a prever: $y(t)$, $y(t - 1), \dots$ Ou, por exemplo, valores passados e futuros da série. Supõe-se que a base de regras contenha duas regras *fuzzy*, do tipo “se-então”, conforme apresentado em (22) e (23).

$$\text{Regra 1: se } x_1 \text{ é } A_1 \text{ e } x_2 \text{ é } B_1 \text{ então } f_1 = p_1 x + q_1 y + r_1, \quad (22)$$

$$\text{Regra 2: se } x_1 \text{ é } A_2 \text{ e } x_2 \text{ é } B_2 \text{ então } f_2 = p_2 x + q_2 y + r_2, \quad (23)$$

em que A_1 e A_2 são os conjuntos *fuzzy* da variável x_1 , já B_1 e B_2 , os conjuntos *fuzzy* da variável x_2 . É importante frisar que o elemento consequente de cada regra é uma combinação linear das variáveis de entrada, x_1 e x_2 , e corresponde a uma previsão para o valor da variável de saída y . Se x_1 e x_2 são os valores passados da própria variável de

saída, então os consequentes das regras são modelos lineares autoregressivos. Dessa forma, cada regra fornece uma previsão para a variável de saída, sabendo que o resultado dessa saída é obtido por meio de (24).

$$y = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2}. \quad (24)$$

2.4.3 LSTM

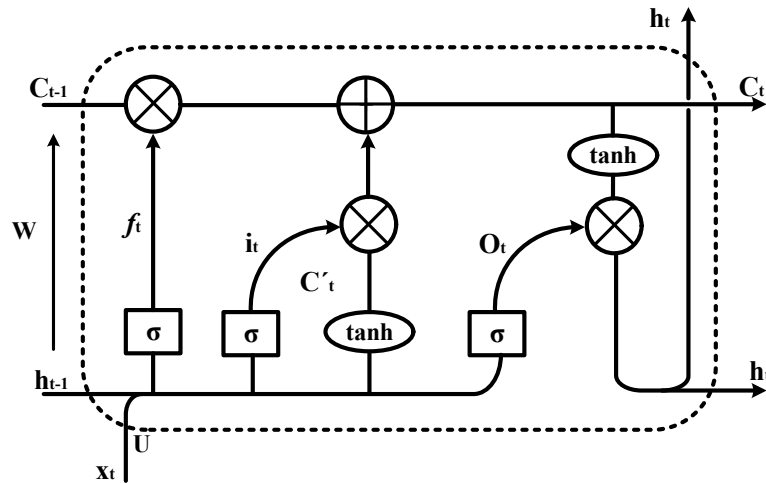
As redes LSTMs, que foram introduzidas por (HOCHREITER & SCHMIDHUBER, 1997), são derivadas das Redes Neurais Recorrentes (RNNs, do inglês *Recurrent Neural Networks*). Esse tipo de rede busca suprimir as dificuldades enfrentadas, com relação ao aprendizado de dependências, nas soluções de problemas que envolvem vários estágios de processamento (GOODFELLOW *et al.* 2016; GREFF *et al.* 2016). Esse tipo de problema está associado ao fato de que muita informação relevante do começo de uma sequência pode ser esquecida no final ou em algum momento em que ela será necessária, após diversas iterações que provocam atualizações no estado oculto da rede neural recorrente. Com relação à aplicação, as redes LSTMs são geralmente empregadas para classificar, processar e prever STs.

Com relação à aplicação, as LSTMs são destinadas, em especial, para resolver problemas que envolvem análise de grande quantidade de dados, tendo em vista o seu desempenho satisfatório para problemas dessa natureza. Dessa forma, a rede LSTM também é recomendada para ser empregada na previsão do comportamento de STs. Ademais, esse tipo de rede é muito aplicado para compreensão de texto. Segundo (BESSA, 2018), a partir de 2016, as empresas de relevância no âmbito internacional, tais como Google®, Apple® e Amazon® passaram a utilizar esse tipo de rede neural para diversos produtos, em especial para os produtos de reconhecimento de voz, tendo como exemplos: Google Tradutor, Siri e Alexa.

Tendo em vista a origem das LSTMs, elas possuem as mesmas propriedades que uma RNN padrão apresenta, embora seja capaz de armazenar informações por longos períodos de tempo ao processar uma sequência de dados. Com relação à sua estrutura, os nós de memória de uma LSTM são denominados de células, com propriedades mais complexas que suas equivalentes nas RNNs tradicionais. Devido à essa complexidade, é possível carregar informações até o final do processamento de uma sequência, como também selecionar informações que não são relevantes para solução do problema, para

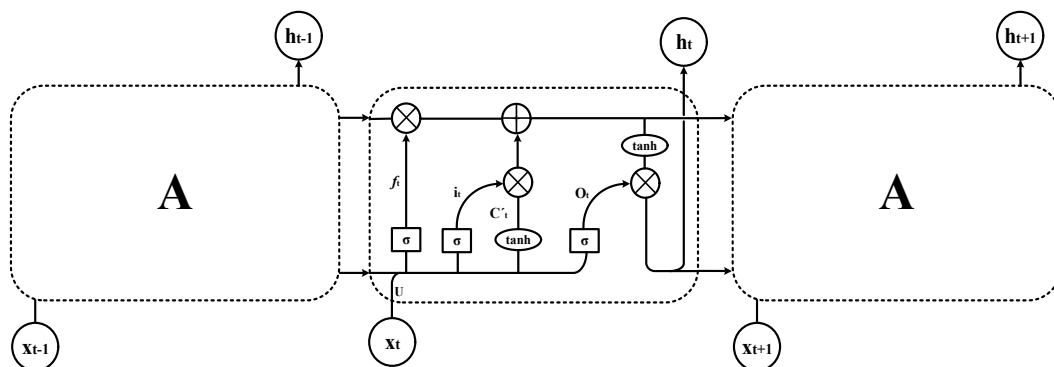
serem esquecidas. Apresentam-se nas Figuras 19 e 20 a representação de uma célula LSTM e uma ilustração do seu funcionamento, respectivamente.

Figura 19 – Representação de uma célula LSTM.



Fonte: adaptado de (OLAH, 2015).

Figura 20 – Representação de uma célula LSTM sendo replicada no tempo.



Fonte: adaptado de (OLAH, 2015).

Com base na Figura 19, verifica-se que, no instante t , C_t representa o estado da célula; h_t , a saída; x_t , a amostra da sequência; f_t , o *gate* de esquecimento; i_t , o *gate* de entrada; e O_t , o *gate* de saída. Conforme a ilustração do circuito, todas essas variáveis, durante o processamento, são concatenadas, multiplicadas ou somadas. E, ainda, W e U são os vetores de pesos para f_t , C_t , i_t e O_t . No tocante às funções de ativação, utilizam-se σ (*sigmoid*) e \tanh (tangente hiperbólica) com faixa de valores de 0 a 1 e -1 a 1, respectivamente. Ainda com base na Figura 19, verifica-se que existem cinco pontos de conexão com exterior da célula, representados por: C_{t-1} , h_{t-1} , x_t , C_t e h_t , sendo os dois primeiros pontos responsáveis por guardar informações passadas

Para operação da LSTM, utilizam-se três portas: entrada, esquecimento e saída, que são denotadas por I_t , f_t e O_t , respectivamente. A porta de entrada determina os valores da entrada para atualizar o estado da memória; já a porta de esquecimento é responsável por determinar as informações que podem ser dispensadas do bloco; e a porta de saída determina o que se pode produzir com base na entrada e saída do bloco. A relação dessas portas com a célula é apresentada na Figura 19. Essas portas empregam a entrada e o estado oculto anterior h_{t-1} , conforme apresentado em (25), (26) e (27). Conta-se que as portas são dependentes de h e x . Assim, é esperado que novo estado de memória (saída da célula) seja calculado por meio de (28).

$$f_t = \sigma(x_t U_f + h_{t-1} W_f), \quad (25)$$

$$I_t = \sigma(x_t U_i + h_{t-1} W_i), \quad (26)$$

$$O_t = \sigma(x_t U_o + h_{t-1} W_o), \quad (27)$$

$$C_t = f_t C_{t-1} + I_t C'_t. \quad (28)$$

De acordo com (28), verifica-se que alguma informação é perdida (ou esquecida) do estado anterior, em compensação alguma entrada é acrescentada. Para determinar a ocorrência da entrada, faz-se necessário obter mais informações. Assim, é necessário determinar o parâmetro a ser inserido no estado da célula (memória), além da informação já conhecida, I_t . Esse parâmetro é calculado por meio de (29), que permite que um novo estado seja calculado a partir de (30). Por meio desse estado oculto, é possível determinar o que a célula deve esquecer, a entrada e saída da célula na etapa posterior.

$$C'_t = \tanh(x_t U_c + h_{t-1} W_c), \quad (29)$$

$$h_t = O_t \tanh(C_t). \quad (30)$$

3 REVISÃO BIBLIOGRÁFICA

Diversas técnicas de monitoramento e diagnóstico de para-raios amplamente empregadas no SEP baseiam-se na medição da corrente de fuga que percorre o para-raios em direção à conexão com a terra. A principal vantagem desse conjunto de técnicas é a possibilidade de medição de uma grandeza elétrica do equipamento, de forma não invasiva, que é bastante sensível ao nível de degradação do para-raios, sem a necessidade de retirá-lo de operação (CARLSON, GUPTA, SWEETANA, 1986). Por isso, diversos estudos vêm sendo realizados com o intuito de se obter uma técnica confiável que indique o nível de degradação dos para-raios de ZnO.

Apesar dessa busca pela técnica de monitoramento e diagnóstico mais promissora, existe uma carência de estudos que possuem a finalidade de prever a vida útil de para-raios de ZnO, seja utilizando a corrente de fuga total, a sua componente resistiva ou o seu conteúdo harmônico. Essa carência é ainda maior com relação ao emprego de STs, considerando esses indicadores, para previsão da vida útil de para-raios. Dessa maneira, é apresentado a seguir, um levantamento do estado da arte das técnicas destinadas para estimar a vida útil de para-raios por meio da previsão qualitativa (experiência empírica) ou quantitativa (modelos de regressão ou por séries temporais), com o objetivo de evidenciar a evolução das pesquisas nessa área. É também apresentado técnicas que são destinadas ao monitoramento e diagnóstico, tendo em vista a relevância dos indicadores dessas técnicas para a estimação da vida útil dos para-raios.

3.1 LEVANTAMENTO DO ESTADO DA ARTE RELACIONADO À ESTIMAÇÃO DA VIDA ÚTIL DE PARA-RAIOS DE ZNO

Proposta por Fujiwara *et al.* (1982), esta técnica busca estimar a vida útil de para-raios de ZnO mediante a submissão do para-raios à simulação de sobretensões de origem atmosférica, em laboratório. Este trabalho adota como premissa o fato de que o para-raios pode entrar em estado de degradação mais rápido quando submetido a estresses elétricos indesejados, seja ela de origem AC ou de altas correntes quando há ocorrência de descargas atmosféricas. Para constatar isso, testes experimentais com para-raios de ZnO

são realizados, considerando vários tipos de impulsos de correntes distintos, com a finalidade de acompanhar o nível de degradação do objeto de teste. Além da simulação de descargas atmosféricas, são realizados ensaios com os para-raios submetidos a sobretensões AC. A partir dos resultados obtidos com a realização dos ensaios, é constatado a aceleração do nível de degradação do para-raios, tendo em vista o conhecimento prévio das características elétricas e físicas do para-raios em estado de degradação. Desse modo, a vida útil pode ser estimada a partir de testes experimentais, diante da submissão do para-raios à aplicação de sobretensões AC e simulação de descargas atmosféricas a partir da análise das características de degradação do objeto de teste.

Carlson *et al.* (1986) apresentaram uma técnica para estimar o tempo de vida útil de para-raios de ZnO por meio da aplicação de níveis de tensão de estresse elétrico AC, considerando as características elétricas e térmicas do dispositivo. Esta técnica se baseia, principalmente, no comportamento da componente resistiva da corrente de fuga que percorre o para-raios, além de analisar outras variáveis relacionadas às características elétricas e térmicas do objeto de teste. Para realizar a estimativa da vida útil do para-raios, são adotados como parâmetros de análise a capacidade de dissipação térmica; o comportamento da corrente resistiva como função da temperatura e tempo, para uma faixa de operação de tensão típica; a constante de crescimento da corrente resistiva como função da tensão e temperatura; e a perda de potência referente ao para-raios como função da tensão aplicado sobre o mesmo e a temperatura. Desse modo, o tempo de vida útil do para-raios é estimada a partir da análise do comportamento da perda de potência em função da temperatura, bem como, do estudo da corrente resistiva e a sua constante de crescimento em função da tensão e temperatura. Com isso, o tempo de vida do para-raios analisado é estimado, considerando níveis de tensão distintos, condições térmicas variadas e configurações do para-raios também variadas.

Ringler *et al.* (1997) propuseram uma técnica de estimar o tempo de falha de para-raios de ZnO por meio da análise da capacidade de absorção de energia, considerando níveis de pico de corrente de 0,8 A até 35 kA. Para tanto, foi necessário obter o produto entre o tempo de falha e o valor da corrente média, de modo que se constatou que tal valor é cinco vezes maior. Esse fator de aumento foi empregado para identificar o tempo de falha do para-raios e, conseqüentemente, estimar a vida útil desses elementos. O trabalho em questão possui como contribuição a indicação de um novo parâmetro para estimar a vida útil dos para-raios de ZnO.

A técnica proposta por Wen & Zhou (2004) possui a finalidade de realizar previsão da vida útil de para-raios de ZnO baseada no impulso de corrente, considerando instantes de surtos elétricos. Esse método é o primeiro a obter características do para-raios e também quantificá-las sob condições de operação normal, por meio de experimento. Além disso, os pontos característicos de degradação são descritos, considerando a mudança do comportamento do para-raios. A estimação da vida útil dos para-raios é possível por meio de investigações realizadas, considerando pontos e curvas características do objeto de teste. Para relacionar as características obtidas com os experimentos, este trabalho propõe dois métodos, denominados de T e U. No método U, a temperatura é mantida constante e a tensão é variada, com a finalidade de encontrar o ponto referente a $i_i(t)$ em I_0 ; enquanto no método T, a tensão é mantida constante e variada a temperatura para encontrar o mesmo ponto de interesse, o qual é utilizado para predição. A forma de implementação de U e T são semelhantes, com a diferença de que o primeiro determina α_{Ui} e o segundo α_{Ti} , os quais estão relacionados com os valores de corrente de interesse. Os testes realizados em laboratório comprovam a eficácia da técnica de estimação da vida útil de para-raios.

Yuanfang *et al.* (2001) propõe uma técnica para estimar a vida útil de para-raios de ZnO por meio da determinação de pontos característicos de curvas características corrente de fuga resistiva em função do tempo e por meio da condição de similaridade, sendo esses dados obtidos a partir de análise de experimentos de envelhecimento. Nos experimentos realizados são aplicados impulsos de corrente para um mesmo objeto de teste (para-raios de ZnO) para verificar o comportamento da corrente, a fim de determinar o tempo de ocorrência do seu valor de pico. A técnica em discussão se baseia nesse comportamento para estimar a vida útil dos para-raios, tendo em vista que o para-raios quando submetido a um estresse de origem atmosférica, o seu nível de degradação aumenta, de modo que sua vida útil diminui. A partir de testes realizados, é possível constatar que o comportamento da corrente impulsiva apresenta um padrão bem definido, seja considerando a tensão constante e temperatura variando ou a tensão variando e a temperatura constante.

A metodologia proposta por Kannus & Lahti (2005) possui como intuito avaliar a condição operacional e confiabilidade de para-raios de ZnO empregados em sistemas de média tensão. Para isso, é proposta uma técnica de previsão de falhas com base em dados históricos de para-raios em operação. Isso é realizado por meio de ensaios de impulso de

corrente realizados em laboratório com para-raios verossímeis aos instalados em campo, no tocante a classe e características elétricas.

O trabalho proposto por Zhou *et al.* (2007) possui a finalidade de estimar a vida útil de para-raios de ZnO por meio da previsão do comportamento da componente resistiva da corrente de fuga. Esse processo de previsão é realizado por meio do emprego de uma ANN, com topologia recorrente (*feedback*), na qual os dados de entradas da rede neural foram adotados como os valores de pico da componente resistiva da corrente associados a uma ST. A escolha da rede neural para realizar estimação é justificada com base no comportamento não linear da componente resistiva, já que esse tipo de inteligência artificial é apropriado para trabalhar com dados lineares e não lineares, seja na classificação de dados ou previsão de STs.

Liu *et al.* (2012) apresentam duas técnicas de previsão de STs com finalidade determinar a vida útil de para-raios de ZnO a partir da medição componente resistiva da corrente de fuga. Uma dessas técnicas se baseia no emprego de ANN, com topologia não recorrente (*feedforward*); já a outra realiza previsão por meio da aplicação do sistema *Gray*. O conjunto de dados de entrada consiste em valores de pico da componente resistiva da corrente de fuga. Além de ser empregado cada uma dessas técnicas de forma isolada, este trabalho analisado propõe a previsão de STs por meio da combinação dos resultados fornecidos por cada um dos modelos utilizados, a fim de otimizar os resultados e, por consequência, a estimação da vida útil ser mais confiável.

A técnica proposta por Lira *et al.* (2014) teve como finalidade realizar o monitoramento e diagnóstico de para-raios de ZnO com base apenas na medição da corrente de fuga total, dispensando a medição da tensão aplicada sobre o para-raios, além de outros empecilhos de cunho técnico-operacional. Este procedimento, por meio de características extraídas dos sinais de corrente avaliados, realiza a construção da base de dados a ser utilizada no treinamento e teste de um classificador de estados de operação de para-raios. O classificador foi baseado em ANNs denominado de Mapas Auto-Organizáveis (SOMs, do inglês *Self-Organizing Maps*). O classificador de estados possui a capacidade de identificar se o para-raios está defeituoso ou não. Caso o para-raios esteja defeituoso, é apresentado o tipo de defeito, tais como: perda de estanqueidade, poluição superficial, degradação de varistores, umidade interna, desalinhamento da coluna ativa e distribuição irregular de tensão. Resultados satisfatórios foram obtidos no diagnóstico, visto que a taxa de acerto para identificação de para-raios defeituosos foi de aproximadamente 98%.

Lima Júnior *et al.* (2014) propôs um procedimento de monitoramento de para-raios baseado na análise da corrente de fuga total por meio de técnicas estatísticas. No desenvolvimento do trabalho foram realizadas medições em campo em para-raios de fabricantes e tempos de operação variáveis. Com isso, foram obtidos sinais de corrente de para-raios com 8, 15 e 20 anos de operação. A partir dos dados medidos em campo e do emprego de técnicas de processamento de sinais e estatística, foi possível observar o comportamento gaussiano dos dados e o crescimento do valor médio da componente de 3ª harmônica da corrente total em função do tempo de operação, evidenciando, assim, a correlação entre a elevação da corrente de fuga e a diminuição da vida útil dos para-raios.

Kim (2015) apresenta uma técnica para estimar a vida útil de para-raios de ZnO com base na elaboração de um histórico de dados com características não lineares obtidos por meio de ensaios realizados com um gerador de impulso de corrente, a fim de submeter o para-raios à estresse elétrico. O método de estimação de vida útil é baseado na quantidade de fluxo de energia que é dissipada pelo para-raios, bem como, no nível de tensão atrelado ao impulso. Nos ensaios realizados em laboratório, foram simuladas formas de ondas de 8/20 μ s para a geração de impulsos de correntes, a fim de simular descargas atmosféricas.

Bokoro & Jandrell (2016) apresentam uma técnica para prever a ocorrência de falhas em para-raios de ZnO. Esses autores verificaram que o tempo de falha diminui diante da presença de harmônios no sinal de tensão do sistema elétrico. Essa foi a premissa adotada para estimar o tempo de falha do para-raios. Para tanto, testes em laboratório foram realizados para simular níveis de degradação distintos, por meio de elevadas temperaturas e sobretensões com a presença de harmônicos na sua constituição. Referente às implementações, são empregados o método probabilístico de Weibull, com três parâmetros, a fim de analisar o tempo de falha estimado, bem como, a taxa de erro obtida. Os resultados apresentados pelo trabalho em discussão indicam que, para 6,24% e 5,58% nas componentes de 3ª e 5ª ordem em relação à fundamental da tensão, o nível de degradação é acelerado em 58,93%, de modo que o tempo de o para-raios falhar é reduzido.

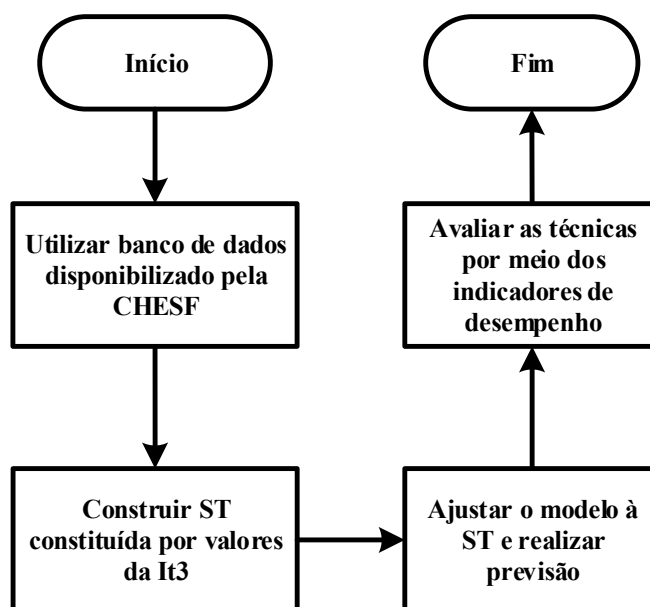
A técnica apresentada por Doorsamy & Bokoro (2018) propõe um novo indicador do nível de degradação de varistores de ZnO, que é utilizado para realizar a estimação da vida útil desses equipamentos. Esse indicador é o nível DC (*Direct Current*) da corrente de fuga total, o qual foi validado em laboratório. Na etapa da validação, realizou-se o envelhecimento precoce de varistores, por meio de estresse térmico e elétrico,

simultaneamente, com base no modelo de Arrhenius. Nesse modelo, o nível de degradação é associado à temperatura que o equipamento está submetido durante um intervalo de tempo, de modo que é possível obter STs de grandezas elétricas vinculadas ao nível de degradação do varistor, tais como os sinais da corrente de fuga total e tensão aplicada obtidos durante o processo de envelhecimento.

4 METODOLOGIA

Para avaliação do desempenho das técnicas de previsão de STs, com o intuito de estimar a vida útil de para-raios de ZnO, quatro etapas foram essenciais: levantamento do estado da arte das técnicas de previsão de STs; utilização do banco de dados constituído por ST com valores da terceira componente harmônica da corrente de fuga; implementação computacional das técnicas de previsão de ST; e avaliação do desempenho de cada uma dessas técnicas. Na Figura 21 é apresentado um fluxograma da metodologia utilizada neste trabalho.

Figura 21 – Fluxograma da metodologia empregada neste trabalho.



Fonte: próprio autor.

No tocante à constituição do banco de dados para criação dos modelos de previsão, ele é constituído com informações referente à terceira componente harmônica da corrente de fuga total, que é um ótimo indicador do nível de degradação de para-raios de ZnO, conforme constatado na literatura (LIRA, 2007; MACÊDO, 2010; IEC 60099-5, 2013; LIMA JÚNIOR, 2014). Já as implementações computacionais foram realizadas com técnicas que empregam modelos baseados em inteligência artificial, com o intuito de prever o comportamento da ST. Por fim, a avaliação das técnicas foi realizada por meio da análise dos indicadores de desempenho adotados, tais como: Erro Absoluto Médio (MAE, do inglês *Mean Absolute Error*), Erro Percentual Absoluto Médio (MAPE, do

inglês *Mean Absolute Percentage Error*) e Erro Médio Quadrático (MSE, do inglês *Mean Square Error*).

Com a finalidade de apresentar informações julgadas como relevantes para o entendimento da metodologia, a seguir, serão apresentadas as descrições de cada uma das etapas citadas anteriormente, com exceção do levantamento do estado da arte, haja vista que ele já foi abordado neste trabalho.

4.1 CONSTITUIÇÃO DO BANCO DE DADOS DE SÉRIES

TEMPORAIS

Na etapa para construção do banco de dados constituído de ST com informações correspondentes aos sinais da corrente de fuga total, em especial a sua terceira componente harmônica, os dados referentes à corrente de fuga foram obtidos por meio de registros realizados por uma empresa de energia elétrica, pertencente à Companhia Hidrelétrica do São Francisco (CHESF). Esses sinais de corrente são de para-raios do mesmo modelo/fabricante, com tempo de operação distinto entre eles. Esse tempo de operação abrange o início, meio e fim da vida útil de para-raios de ZnO.

O banco de dados constituído pela ST com valores da terceira componente harmônica da corrente de fuga total foi construído a partir de medições e registros dos sinais da corrente de fuga referente a um conjunto de para-raios de ZnO, em subestação pertencente à CHESF. A ST adotada para análise é apresentada na Figura 10. Os dados técnicos, de placa, dos para-raios correspondentes aos sinais de corrente, que constituem o banco de dados, são apresentados na Tabela 2. A título de informação, o sistema no qual os para-raios são instalados é de 69 kV (RMS).

4.2 TÉCNICAS UTILIZADAS PARA PREVISÃO DE SÉRIES

TEMPORAIS

Com relação à etapa da implementação das técnicas, os algoritmos correspondentes a cada uma das técnicas foram formulados por meio da plataforma computacional MATLAB®. As técnicas de previsão de STs, para estimação da vida útil

de para-raios, foram implementadas por meio da aplicação de modelos puros e combinaionais baseados em inteligência artificial. Para a elaboração desses modelos, adotaram-se, como foco de análise, as técnicas baseadas em SVM, NFS e LSTM.

Apresentam-se, a seguir, a descrição de quatro técnicas, sendo três delas puras e uma combinacional, que foram empregadas na previsão de ST, para estimação da vida útil de para-raios de ZnO.

Tabela 2 – Dados técnicos dos para-raios de ZnO.

Dados técnicos	Para-raios
Tensão nominal	72 kV (RMS)
Máxima tensão de operação contínua	42 kV (RMS)
Tensão residual máxima	180 kV (pico)
Corrente nominal de descarga	20 kA (pico)
Varistor	ZnO
Invólucro	Porcelana
Idade	31 anos

Fonte: adaptado de (LIMA JÚNIOR, 2014).

4.2.1 TÉCNICA A

Para implementação da técnica A, que é caracterizada por utilizar um modelo puro baseado em SVM, de forma mais específica na SVR que corresponde à SVM adaptada para regressão, por meio da utilização da *Statistics and Machine Learning Toolbox* pertencente ao MATLAB®. Com relação à função *kernel*, utilizou-se a função gaussiana, a qual é apresentada em (31), já que o comportamento da ST respeita uma função exponencial, com tendência crescente.

$$G(x_1, x_2) = \exp(-\|x_1 - x_2\|^2). \quad (31)$$

No tocante ao treinamento e validação do sistema de previsão baseado em SVM, dedicou-se, inicialmente, 10% dos dados para validação do modelo e 90% para treinamento; em outra simulação, utilizou-se 20% dos dados para validação e 80% para treinamento. É importante ressaltar que na literatura (BRAGA *et al.*, 2000) é sugerido a utilização de, pelo menos, 20% dos dados no processo de validação do modelo.

4.2.2 TÉCNICA B

Para implementação da técnica B, utilizou-se o NFS, com arquitetura ANFIS, para realizar previsão do comportamento da ST constituída com valores da terceira componente harmônica da corrente de fuga, que consiste na combinação de ANNs com a lógica *fuzzy*. A ferramenta computacional utilizada foi o MATLAB®, por meio do *Neuro-Fuzzy Designer*.

No tocante às etapas de treinamento e validação do sistema de previsão baseado na arquitetura ANFIS, dedicaram-se, inicialmente, 10% dos dados para validação do modelo e 90% para treinamento. Já em outra simulação, utilizaram-se 20% dos dados para validação e 80% para treinamento. Com relação à geração de conjuntos de dados pertencentes à lógica *fuzzy*, utilizou-se uma configuração padrão sugerida pela *toolbox*, o particionamento de grande (*grid partitioning*, em inglês). Esse tipo de configuração é o mais recomendado na literatura (CICHINE *et al.*, 2000; ANDRADE *et al.*, 2010), em virtude do seu desempenho satisfatório nas aplicações de lógica *fuzzy* para previsão de STs.

4.2.3 TÉCNICA C

A técnica C foi implementada por meio da utilização da rede LSTM com aplicação da *LSTM Network Toolbox* pertencente ao MATLAB®. De forma semelhante para as demais implementações, esse tipo de rede foi destinado para realizar previsão do comportamento de STs, considerando os valores da terceira componente harmônica da corrente de fuga total de para-raios de ZnO.

De forma análoga à distribuição dos dados para treinamento e validação das técnicas A e B, para o modelo criado por meio da rede LSTM também foram dedicados, inicialmente, 10% dos dados para validação e 90% para treinamento do modelo. E, ainda, em outra simulação, dedicaram-se 20% dos dados para validação e 80% para treinamento, conforme é sugerido na literatura.

4.2.4 TÉCNICA D

A fim de implementar um sistema de previsão com resultados mais acurados, implementou-se a técnica D, que faz uso de um modelo combinacional das técnicas A, B e C. Isso é proposto, tendo em vista que os modelos combinacionais apresentam melhores resultados quando comparados à previsão de cada um modelo individual, já que cada uma

das técnicas possui os seus pontos fortes e pontos fracos (GEORGOFF & MURDICK, 1986). E, ainda, segundo (ORD, 2001) a acurácia dos modelos combinacionais supera, na média, os modelos individuais utilizados na combinação.

Devido à essa superioridade dos modelos combinacionais com relação aos modelos individuais, utiliza-se um modelo combinacional por meio do emprego dos três modelos empregados nas técnicas A, B e C. A combinação entre essas técnicas de previsão é dada a partir de uma combinação linear das previsões. A previsão combinada, dessa maneira, pode ser interpretada como a média ponderada das previsões dos modelos individuais, na qual a soma dos pesos associados a cada um dos modelos (ρ_{SVM} , ρ_{NFS} e ρ_{LSTM}) é igual ao valor unitário, conforme apresentado em (32).

$$y_{Com} = \rho_{SVM}y_{SVM} + \rho_{NFS}y_{NFS} + \rho_{LSTM}y_{LSTM} = 1, \quad (32)$$

em que y_{Com} representa o valor da previsão baseada no modelo combinacional, já y_{SVM} , y_{NFS} e y_{LSTM} representam, respectivamente, as previsões individuais realizadas pelos modelos baseados em SVM, NFS e LSTM.

Para realizar a previsão por meio do modelo combinacional, tendo em vista que os modelos correspondentes às técnicas já tenham sido implementados, inicialmente foram determinadas metas para cada tipo de métrica considerada neste trabalho (MSE, MAE e MAPE). Para isso, utilizou-se a ferramenta *solver* pertencente ao Excel, que é comercializado pela Microsoft®. Desse modo, variando os pesos, ρ_{SVM} , ρ_{NFS} e ρ_{LSTM} , da combinação linear das previsões e utilizando a restrição apresentada em (32), calcula-se o valor mínimo para cada medida de desempenho, que foi determinado como meta associado a cada erro.

Nesse sentido, os pesos foram variados novamente, obtendo novos valores para as métricas. Para possibilitar que esses valores se minimizassem concomitantemente, propôs-se que o somatório dos desvios das novas métricas calculadas em relação às suas respectivas metas fossem o menor possível. Para tanto, aplicou-se mais uma vez a ferramenta *solver*, considerando a expressão (33) e a condição (34) para alcançar o resultado almejado.

$$\sigma_{Som} = \frac{MSE - Meta_{MSE}}{Meta_{MSE}} + \frac{MAE - Meta_{MAE}}{Meta_{MAE}} + \frac{MAPE - Meta_{MAPE}}{Meta_{MAPE}}, \quad (33)$$

$$\sigma_{Min} = \min(\sigma_{Som}). \quad (34)$$

em que σ_{Som} é o somatório dos desvios das novas métricas em relação as suas respectivas metas e σ_{Min} é o valor σ_{Som} minimizado por meio da ferramenta *solver*.

Após o processo de minimização de σ_{Som} , calcularam-se os valores de ρ_{SVM} , ρ_{NFS} e ρ_{LSTM} correspondentes aos valores dos pesos da combinação linear do modelo combinacional, conforme apresentado na Tabela 3, considerando as duas distribuições de dados adotadas neste trabalho. Essas distribuições são análogas às distribuições de dados adotadas para as técnicas A, B e C. Ou seja, na primeira simulação, adotaram-se 10% dos dados para validação e 90% para treinamento do modelo combinacional. E, ainda, em outra simulação, dedicaram-se 20% dos dados para validação e 80% para treinamento.

Tabela 3 – Valores dos pesos do modelo combinacional para horizontes de previsão com 24 e 48 meses à frente.

Horizonte de previsão (meses)	ρ_{SVM}	ρ_{NFS}	ρ_{LSTM}	Total
24	0,39	0,33	0,28	1,00
48	0,31	0,65	0,04	1,00

Fonte: próprio autor.

4.3 INDICADORES DE DESEMPENHO

As técnicas de previsão abordadas neste trabalho foram avaliadas por meio de índices estatísticos, a fim de avaliar o desempenho no processo de previsão de cada uma delas. Dentre os índices apresentados em (HONG, 2018), adotaram-se três tipos de erros: MSE, MAE e MAPE. Esses tipos de erros são determinados por (35), (36) e (37), respectivamente.

$$MSE = \frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2, \quad (35)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |\hat{y}_t - y_t|, \quad (36)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{y}_t - y_t}{y_t} \right| \times 100, \quad (37)$$

em que n é o número total de observações da série temporal, \hat{y}_t representa os valores estimados e y_t representa os valores medidos ou observados.

O emprego do MSE é relevante para análise dos resultados de previsão, uma vez que esse erro permite verificar a acurácia dos dados estimados por cada uma das técnicas abordadas neste trabalho. A vantagem desse tipo de erro é sua sensibilidade aos grandes erros, por elevar as diferenças individuais ao quadrado, conforme apresentado em

(WILKS, 2006). Tendo em vista sua definição apresentada em (35), o MSE é sempre positivo. Como forma de interpretação desse indicador, depreende-se que a simulação (processo de previsão) é perfeita se MSE for igual a zero, isto é, quanto menor o MSE mais confiável são os dados de previsão.

Com relação ao emprego do MAE, é uma métrica importante que possibilita verificar a exatidão dos dados estimados pelas técnicas de previsão de STs. Esse indicador é caracterizado por calcular a média dos valores absolutos dos desvios, conforme apresentado em (36). Neste caso, é atribuído o mesmo peso a todas as diferenças, de modo linear. A interpretação do MAE é semelhante ao MSE, isto é, quanto menor é o erro obtido, mais confiável são os dados de previsão.

Diante do emprego dos erros MSE e MAE, pode-se enfrentar algumas dificuldades na interpretação dos resultados obtidos a partir desse tipo de erro, pois os valores comparados podem ser da ordem de milhar (ou até milhão), por exemplo, de modo que o erro possa ser consideravelmente grande. Para solucionar esse problema, utiliza-se o MAPE, que consiste em um erro percentual e é normalizado pelos valores adotados como referência, conforme apresentado em (37) (MYTTENAERE *et al.*, 2016). Esse tipo de erro percentual possibilita quantificar a exatidão dos valores estimados pela técnica de previsão. Como forma de interpretação do MAPE, quanto menor o seu valor, mais confiáveis são as previsões realizadas.

5 RESULTADOS E ANÁLISES

Para aplicar a metodologia apresentada neste trabalho, faz-se necessário analisar os resultados obtidos por meio das técnicas de previsão de STs implementadas, considerando os indicadores de desempenho adotados. A maneira como essas técnicas foram avaliadas baseia-se no comportamento dos indicadores de desempenho apresentados no Capítulo 4 que descreve a metodologia deste trabalho. Espera-se que os valores dos indicadores MSE, MAE e MAPE sejam os menores possíveis, a fim de que a previsão realizada por cada uma das técnicas seja confiável, considerando a aplicação das técnicas A, B, C e D.

Uma vez realizada a previsão do comportamento da ST, com valores da terceira componente harmônica da corrente de fuga de para-raios de ZnO, sendo realizada com sucesso por meio de cada uma das técnicas avaliadas, é possível prever a vida útil desse equipamento de proteção. Isso é justificado pelo fato dessa grandeza ser um indicador do nível de degradação de para-raios. Além disso, já é preconizado na literatura valores limites dessa grandeza para retirada imediata de para-raios de ZnO que estiverem em operação. Por exemplo, caso o valor de I_{t3} ultrapasse 0,1 mA (100 μ A), recomenda-se a retirada do para-raios de serviço (TRIDELTA, 2007). Com isso, manutenções preditivas em para-raios contra falhas, programadas e não programadas, podem ser realizadas por meio do emprego de técnicas que realizam previsão do comportamento de STs.


Nas implementações das técnicas A, B, C e D, utiliza-se a mesma base de dados constituída pela ST com valores da terceira componente harmônica da corrente de fuga total. Essa ST possui o intervalo de vinte e um anos, desde o ano de 1995 até 2015, de modo que abrange três estágios do ciclo de operação do para-raios com relação à sua vida útil: início, meio e fim. Uma vez criado o modelo baseado em inteligência artificial, realizaram-se previsões com horizontes de 24 e 48 meses à frente, considerando que o modelo foi ajustado à ST com sucesso.

Apresentam-se, a seguir, os resultados obtidos por meio da implementação de cada uma das técnicas A, B, C e D, considerando as duas distribuições de dados adotadas neste trabalho, além da comparação entre os indicadores de desempenho correspondentes a cada uma dessas técnicas.

5.1 RESULTADOS OBTIDOS PELA TÉCNICA A


Dentre as técnicas implementadas, apresenta-se inicialmente a técnica A, a qual se baseia na aplicação da SVM, em especial a SVR, para criação de um modelo verossímil à ST e, em seguida, previsões são realizadas do comportamento da ST por meio do modelo criado. Para implementação desta técnica, as suas características (e.g., excelente capacidade de generalização e possibilidade de tratar dados não lineares) foram relevantes para o processo de previsão. Como resultados, apresentam-se nas Figuras 22 e 23, respectivamente, as previsões realizadas pela técnica A para os horizontes de 24 e 48 meses à frente.

Figura 22 – Previsões para 24 meses à frente, obtidas pela técnica A, com o emprego da SVM.



Fonte: próprio autor.

Figura 23 – Previsões para 48 meses à frente, obtidas pela técnica A, com o emprego da SVM.



Fonte: próprio autor.

Por inspeção gráfica, com base nas Figuras 22 e 23, as previsões realizadas pela técnica A foram satisfatórias, para os dois horizontes de tempo considerados (24 e 48 meses), pois ambas respeitam o comportamento da ST medida durante 252 meses. Para a previsão com horizonte de tempo de 24 meses, verifica-se, por inspeção gráfica, que as previsões se ajustam de forma satisfatória à parcela da ST destinada para validação. Já para a previsão com horizonte de 48 meses, constata-se que as previsões foram aquém das previsões para horizonte de 24 meses, com relação ao acompanhamento da tendência da ST adotada como referência.

O desempenho do modelo implementado pela técnica A foi avaliado por meio do emprego dos indicadores de desempenho, MSE, MAE e MAPE. Esses indicadores possibilitam avaliar a qualidade das previsões realizadas. Para a previsão com horizonte de 24 meses à frente, os valores obtidos pela técnica A, para esses indicadores, foram:

$$MSE = 1,21 \times 10^{-14}, \quad (38)$$

$$MAE = 9,74 \times 10^{-8}, \quad (39)$$

$$MAPE = 0,64 \%, \quad (40)$$

tendo em vista que o significado desses valores está relacionado com a qualidade das previsões realizadas. Por exemplo, 0,64% das previsões realizadas pela técnica A são falhas, para o horizonte de previsão considerado.

Já a previsão com horizonte de 48 meses à frente apresenta maiores erros, conforme apresentado em (41), (42) e (43). Esses resultados confirmam a análise gráfica relatada anteriormente, haja vista que as previsões não conseguem acompanhar tão bem os dados reais como na distribuição de dados para 24 meses.

$$MSE = 9,67 \times 10^{-14}, \quad (41)$$

$$MAE = 2,89 \times 10^{-7}, \quad (42)$$

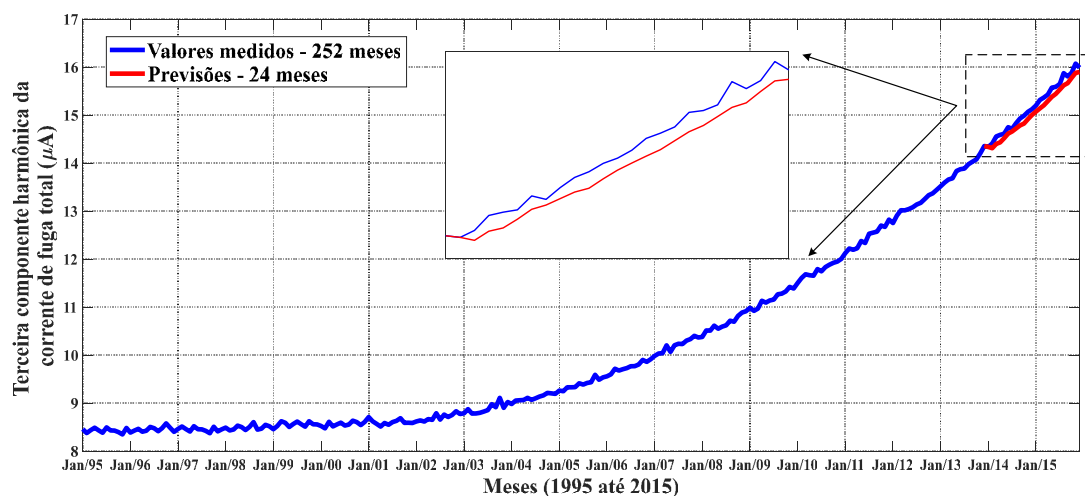
$$MAPE = 2,07\%. \quad (43)$$

Diante dos resultados obtidos por meio da implementação da técnica A, constata-se que eles foram satisfatórios, haja vista que os valores obtidos dos erros foram próximos de zero, para ambos os horizontes avaliados. Apesar dos resultados satisfatórios, verifica-se que os erros aumentam com o aumento de horizonte de previsão. Isso ocorre em virtude da previsão ser livre, ou seja, os valores previstos não são atualizados em cada iteração.

5.2 RESULTADOS OBTIDOS PELA TÉCNICA B


No tocante à técnica B, para sua implementação foi utilizado o NFS, com arquitetura ANFIS, para criação de um modelo com finalidade de representar a ST adotada para análise, e, em seguida, realizar previsão do seu comportamento para dois horizontes de tempo distintos. Para realizar sua implementação, não foi preciso ter conhecimento estatístico da ST a ser prevista, tendo em vista que o sistema baseado em NFS possui a capacidade de autoaprendizagem, além de autodirecionamento. Como resultados, apresentam-se nas Figuras 24 e 25, respectivamente, as previsões realizadas, pela técnica B, para os horizontes de 24 e 48 meses à frente.

Figura 24 – Previsões para 24 meses à frente, obtidas pela técnica B, com o emprego da NFS.



Fonte: próprio autor.

Figura 25 – Previsões para 48 meses à frente, obtidas pela técnica B, com o emprego da NFS.



Fonte: próprio autor.

Considerando os resultados apresentados nas Figuras 24 e 25, para os dois horizontes de tempo considerados nas implementações realizadas com a técnica B, as previsões foram, de modo geral, satisfatórias, já que elas respeitam o comportamento da

ST. Considerando os resultados de previsão com horizonte de 24 meses em relação ao horizonte de 48 meses à frente, constata-se que o primeiro conjunto de resultados de previsão é mais exato do que o segundo conjunto, considerando a inspeção gráfica.

De forma semelhante à técnica A, o desempenho da técnica B foi avaliado por meio do emprego dos indicadores MSE, MAE e MAPE. Para previsão com horizonte de 24 meses à frente, os valores obtidos pela técnica B são apresentados em (44), (45) e (46). O resultado obtido para o MAPE significa que 0,44% das previsões são falhas e, de acordo com os valores do MSE e MAE, as previsões indicam pouca variância em relação a parcela da ST medida.

$$MSE = 7,26 \times 10^{-15}, \quad (44)$$

$$MAE = 6,70 \times 10^{-8}, \quad (45)$$

$$MAPE = 0,44\%. \quad (46)$$

Para as previsões com horizonte de 48 meses à frente, de modo análogo aos resultados obtidos pela técnica A, os erros obtidos nas simulações da técnica B são maiores, de acordo com (47), (48) e (49). E, ainda, pode-se constatar que 1,01% das previsões são falhas, considerando o horizonte de 48 meses à frente.

$$MSE = 2,29 \times 10^{-14}, \quad (47)$$

$$MAE = 1,42 \times 10^{-7}, \quad (48)$$

$$MAPE = 1,01\%. \quad (49)$$


Com base nos resultados obtidos a partir da implementação da técnica B, verifica-se que eles foram satisfatórios, haja vista que os erros obtidos se aproximam de zero, com exceção do MAPE para previsão com horizonte de 48 meses à frente. Embora os resultados, de modo geral, tenham sido satisfatórios, foi possível constatar que os erros aumentam com o horizonte de previsão.

5.3 RESULTADOS OBTIDOS PELA TÉCNICA C

Com relação à técnica C, para sua implementação foi utilizado a rede LSTM para criação do modelo com a finalidade de representar a ST adotada para análise, e, em seguida, realizar previsão do seu comportamento para dois horizontes de tempo distintos. Para implementação dessa técnica, atentou-se para se ter uma grande quantidade de dados na etapa de treinamento, para garantir que a rede LSTM apresentasse desempenho

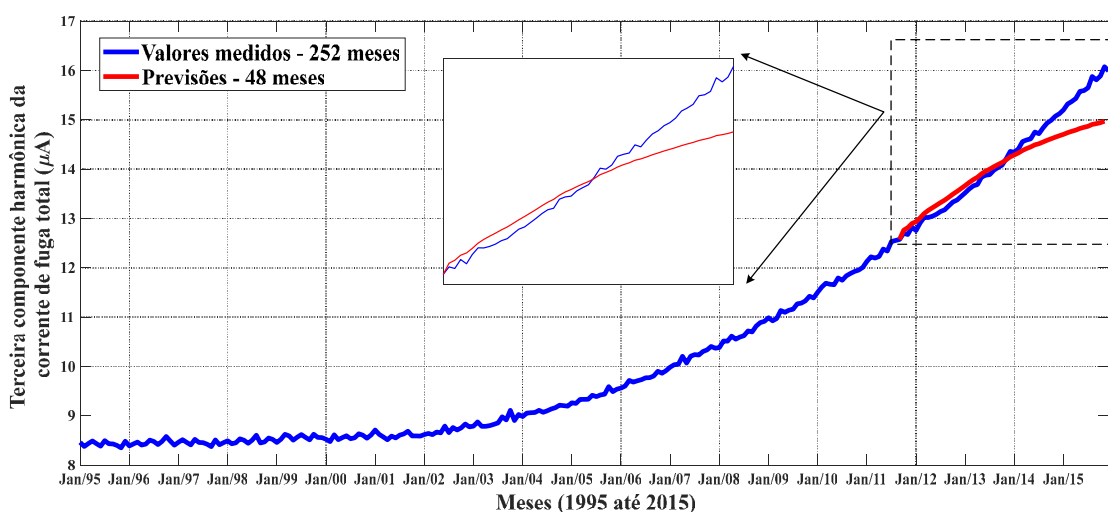
satisfatório no processo de previsão. Os resultados de previsão são apresentados nas Figuras 26 e 27, para horizontes de 24 meses à frente e 48 meses à frente, respectivamente.

Figura 26 – Previsões para 24 meses à frente, obtidas pela técnica C, com o emprego da rede LSTM.



Fonte: próprio autor.

Figura 27 – Previsões para 48 meses à frente, obtidas pela técnica C, com o emprego da rede LSTM.



Fonte: próprio autor.

Considerando o resultado apresentado na Figura 26, verifica-se que a previsão para o horizonte de 24 meses acompanha o comportamento da ST adotada como referência. No entanto, a previsão realizada para o horizonte de 48 meses diverge em relação à ST, conforme apresentado na Figura 27. Assim, constata-se que apenas a previsão para 48 meses à frente é confiável, considerando a análise gráfica.

De forma análoga às técnicas A e B, o desempenho da técnica C foi avaliado por meio do emprego dos indicadores MSE, MAE e MAPE. Para previsão com horizonte de 24 meses à frente, os valores obtidos pela técnica C são apresentados em (50), (51) e (52).

O resultado obtido para o MAPE significa que 0,57% das previsões são falhas e, conforme os valores do MSE e MAE, as previsões indicam pouca variância em relação a parcela da ST medida.

$$MSE = 1,53 \times 10^{-14}, \quad (50)$$

$$MAE = 8,87 \times 10^{-8}, \quad (51)$$

$$MAPE = 0,57\%. \quad (52)$$

Para as previsões com horizonte de 48 meses à frente, de modo análoga aos resultados obtidos pelas técnicas A e B, os erros obtidos nas simulações da técnica C são maiores, de acordo com (53), (54) e (55). E, ainda, pode-se constatar que 1,69% das previsões são falhas, considerando o horizonte de 48 meses à frente.

$$MSE = 9,67 \times 10^{-14}, \quad (53)$$

$$MAE = 2,48 \times 10^{-7}, \quad (54)$$

$$MAPE = 1,69\%. \quad (55)$$

Com base nos resultados obtidos a partir da implementação da técnica C, por análise gráfica, a previsão para o horizonte de tempo de 48 meses não é confiável, tendo em vista a divergência da previsão em relação à ST medida. Já considerando os valores dos indicadores de desempenho, é verificado que as previsões para os dois horizontes de tempo considerados neste trabalho são satisfatórias. Assim, verifica-se a importância da realização de ambas as análises para avaliação da técnica de previsão.

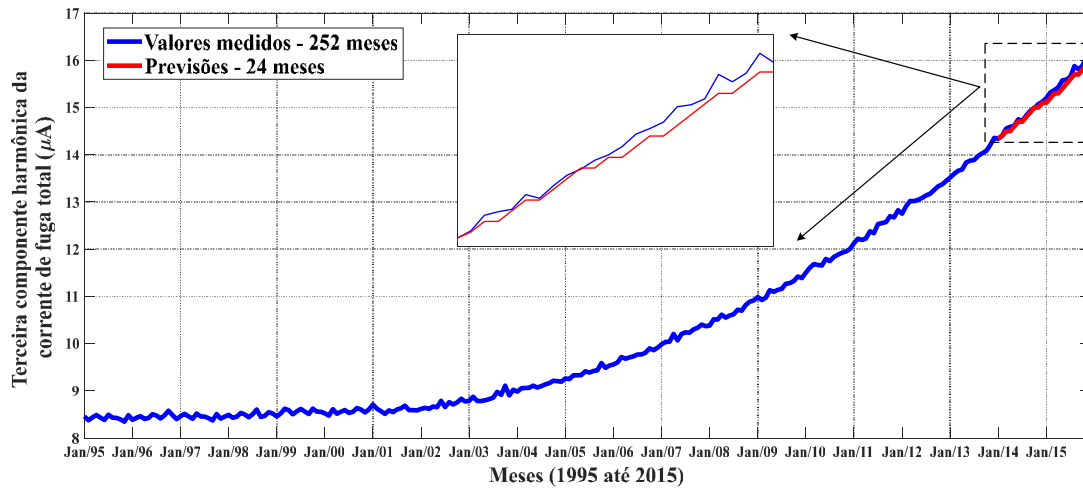
5.4 RESULTADOS OBTIDOS PELA TÉCNICA D

Para a técnica D, caracterizada por ser um modelo combinacional, obtiveram-se os resultados apresentados nas Figuras 28 e 29. Esses resultados consistem em previsões realizadas para horizontes de 24 e 48 meses à frente. Para implementação dessa técnica, foi necessário implementar um modelo resultante da combinação linear das técnicas A, B e C. A partir desses resultados, para os dois horizontes de tempo considerados nas implementações, as previsões foram satisfatórias, uma vez que respeitam o comportamento da ST medida.

No mesmo sentido da forma de avaliação das técnicas A, B e C, o desempenho da técnica D também foi avaliado por meio da análise das métricas MSE, MAE e MAPE. Para previsão com horizonte de 24 meses à frente, os valores obtidos pela técnica D são apresentados em (56), (57) e (58). Considerando o valor do MAPE, verifica-se que 0,29%


das previsões são falhas e, conforme os valores do MSE e MAE, as previsões indicam pouca variância em relação a parcela da ST medida.

Figura 28 – Previsões para 24 meses à frente, obtidas pela técnica D, com o emprego do modelo combinacional.



Fonte: próprio autor.

Figura 29 – Previsões para 48 meses à frente, obtidas pela técnica D, com o emprego do modelo combinacional.



Fonte: próprio autor.

$$MSE = 2,76 \times 10^{-15}, \quad (56)$$

$$MAE = 4,14 \times 10^{-8}, \quad (57)$$

$$MAPE = 0,29\%. \quad (58)$$

Já para as previsões com horizonte de 48 meses à frente, de modo análogo aos resultados obtidos pelas técnicas A, B e C, os erros obtidos nas simulações da técnica D

são maiores, de acordo com (59), (60) e (61). E, ainda, pode-se constatar que 1,69% das previsões são falhas, considerando o horizonte de 48 meses à frente.

$$MSE = 4,46 \times 10^{-15}, \quad (59)$$

$$MAE = 4,50 \times 10^{-8}, \quad (60)$$

$$MAPE = 0,30\%. \quad (60)$$

De acordo com os resultados obtidos por meio da implementação da técnica D, verifica-se que eles foram satisfatórios, haja vista que os erros obtidos se aproximam de zero. Embora os resultados, de modo geral, tenham sido satisfatórios, foi possível constatar que os erros aumentam com o horizonte de previsão, de forma menos significativa para o modelo combinacional.

5.5 COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS PELAS TÉCNICAS A, B, C E D

Com o intuito de comparar os indicadores de desempenho (MSE, MAE e MAPE) adotados neste trabalho, para avaliar as técnicas A, B C e D, apresenta-se a Tabela 4 com os valores desses erros, considerando os dois horizontes de tempo adotados durante as implementações computacionais. Com base nessa tabela, para os horizontes de 24 e 48 meses à frente, os erros apresentados pela técnica D (modelo combinacional) são menores em relação aos erros apresentados pelas técnicas A (SVM), B (NFS) e C (LSTM). Além dessa constatação, verifica-se que as previsões realizadas pela técnica D, para 48 meses à frente, apresentam erros maiores do que as previsões com horizonte de 24 meses à frente. Com relação às técnicas que se baseiam na aplicação de um único modelo, no caso das técnicas A, B e C, os valores dos três tipos de erros adotados neste trabalho são menores para as previsões realizadas pela técnica B, para 24 e 48 meses.

Tendo em vista as constatações referentes ao desempenho de cada uma das técnicas avaliadas com base na Tabela 4, depreende-se que a técnica D possui melhor desempenho em relação às técnicas A, B e C, para os horizontes de 24 e 48 meses à frente. E, ainda, a partir dos resultados apresentados, certifica-se que o desempenho da técnica D melhora para previsão com menor intervalo de tempo. Além disso, constata-se que, entre as técnicas que se baseiam na aplicação de um único modelo, a técnica B se

sobressaí em relação às técnicas A e C, para as previsões com os horizontes de tempo de 24 e 48 meses à frente.

Tabela 4 – Comparação entre o desempenho apresentado por cada uma das técnicas implementadas.

Técnica (modelo)	Previsão de 24 meses à frente			Previsão de 48 meses à frente		
	MAE	MAPE	MSE	MAE	MAPE	MSE
A (SVM)	9,74E-08	0,64%	1,21E-14	2,89E-07	2,07%	9,67E-14
B (NFS)	6,70E-08	0,44%	7,26E-15	1,42E-07	1,01%	2,29E-14
C (LSTM)	8,87E-08	0,57%	1,53E-14	2,48E-07	1,69%	9,67E-14
D (Combinacional)	4,14E-08	0,29%	2,76E-15	4,50E-08	0,30%	4,46E-15

Fonte: próprio autor.

6 CONCLUSÕES

Este trabalho propôs-se a apresentar avaliações de técnicas que empregam modelos baseados em inteligência artificial para previsão do comportamento de ST (valores da terceira componente harmônica da corrente de fuga total), com o intuito dessas técnicas serem empregadas na estimativa da vida útil de para-raios de ZnO. Para que essas avaliações fossem realizadas, este trabalho se restringiu a analisar as técnicas A, B, C e D, com foco na análise dos indicadores de desempenho adotados.

A partir da análise das técnicas de previsão, constataram-se resultados relevantes para auxiliar na escolha das técnicas mais promissoras para serem empregadas na previsão de ST, a fim de estimar a vida útil de para-raios, de modo a possibilitar o gerenciamento de ativos do SEP. Considerando os valores dos indicadores de desempenho adotados, verificou-se que as técnicas avaliadas foram bem-sucedidas no processo de previsão do comportamento da ST.

Apesar disso, por análise gráfica, verificou-se que a técnica C não é confiável para o horizonte de tempo de 48 meses, em razão da divergência da previsão realizada em relação à ST adotada como referência. E, ainda, no tocante ao desempenho das técnicas considerando os valores dos indicadores de desempenho, constatou-se que a técnica D possui desempenho superior em relação às técnicas A, B e C, para os horizontes de tempo de 24 e 48 meses à frente. Ademais, com relação às técnicas que se baseiam na aplicação de um único modelo, verifica-se que a técnica B apresenta melhor desempenho, para ambos os horizontes de tempo considerados neste trabalho.

O objetivo geral e os objetivos específicos destinados para este trabalho foram atingidos. Em primeiro lugar, realizou-se o levantamento do estado da arte, com foco na análise das técnicas destinadas a estimar o tempo de vida útil de para-raios de ZnO, sendo algumas delas baseadas na análise de previsão do comportamento de ST. Em segundo lugar, fez-se o estudo teórico sobre as técnicas destinadas para estimar a vida útil de para-raios, com foco nas técnicas que usam previsão de ST, com a finalidade de assimilar os conceitos necessários para analisar cada uma delas. Dentre as técnicas analisadas, priorizaram-se as técnicas baseadas em inteligência artificial, as quais foram tituladas de A, B, C e D, que utilizaram, respectivamente, a SVM, o NFS, a rede LSTM e o modelo

combinacional. Por fim, os indicadores de desempenho (MSE, MAE e MAPE) foram avaliados, com base nos resultados apresentados pelas técnicas implementadas.

O estudo avaliativo das técnicas de previsão de ST baseadas em inteligência artificial, com intuito de estimar a vida útil dos para-raios de ZnO, possui fundamental importância para o âmbito acadêmico e o SEP. Dentre as contribuições realizadas até o momento, a análise do desempenho das técnicas de previsão com base na inspeção gráfica e nos indicadores de desempenho adotados, a constatação do êxito no processo de previsão realizado pelas técnicas A, B, C (com exceção para o horizonte de 48 meses) e D, com destaque para o desempenho da técnica D, são as principais contribuições deste TCC. Diante do conteúdo exposto, o gerenciamento de ativos do SEP pode ser realizado de forma mais confiável, além de que manutenções preditivas podem ser executadas para evitar falhas de para-raios de ZnO, por meio do conhecimento de sua vida útil.

REFERÊNCIAS

- ABB. **High Voltage Surge Arresters**. [S.l.: s.n.], 2016.
- ABB. **Excourt II - User's Manual**. [S.l.], 2010.
- ABB. **Selection guide for ABB HV surge arresters**. [S.l.], 1995.
- ANDRADE, L. C. et al. **Sistemas Fuzzy para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo**. In: 9th Brazilian Conference on Dynamics Control and Their Applications, 2010.
- ABB. **High Voltage Surge Arresters**. [S.l.: s.n.], 2016.
- BALLINI, R. **Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais Artificiais e Redes Neurais Nebulosas**. Tese (Doutorado) - Universidade Estadual de Campinas, Campinas, setembro 2000.
- BARGIGIA, A.; GIANNUZZI, L.; INESI, A.; PARRINO, A.; PIGINI, A. **Study of the performance of metal oxide arresters for high voltage systems**. In: International Conference on Large High Voltage Electric Systems. 1986.
- BESSA, Adriana Bezerra. **Previsão de vendas no varejo de moda com modelos de redes neurais**. 2018. Tese de Doutorado.
- BHAT, U. Narayan, and Gregory K. Miller. **Elements of applied stochastic processes**. J. Wiley, 1972.
- BOKORO, P. & JANDRELL, I. **Failure analysis of metal oxide arresters under harmonic distortion**. Proc. IEEE Int. Conf. Environ. Elect. Eng., pp. 1-4, Jun. 2016.
- BRAGA, A.P.; CARVALHO, A.C.; LUDEMIR, T.B. **Redes Neurais Artificiais: teoria e aplicações**. Livraria Técnica Científica, 2000.
- BRITO, V. S. **Modelo elétrico de supressor de surto de ZnO com ampla faixa de operação**. Tese (Doutorado) - Universidade Federal de Campina Grande, Campina Grande, outubro 2016.
- CARLSON, W. G.; GUPTA, T. K.; SWEETANA, A. **A Procedure for Estimating the Lifetime of Gapless Metal Oxide Surge Arresters**. IEEE Transactions on Power Systems, v. 1, n. 2, p. 67-73, April 1986.
- CICHINI, F. A. L.; CASTRO, R.; FLAUZINO, R. A. **Uma abordagem baseada em sistemas de inferência fuzzy para estimação de cotações de ações**. In: XXVII Encontro Nacional de Engenharia de Produção, 2007.
- CORTEZ, P. **Algoritmos genéticos e redes neuronais na previsão de séries temporais**. Dissertação (Mestrado) - Universidade do Minho, Minho, dezembro.
- COVER, T.M. **Geometrical and Statistical properties of systems of linear inequalities with applications in pattern recognition**. IEEE Transactions on Electronic Computers. EC-14: 326-334. 1965.

- COSTA, E. G. **Análise do Desempenho de Para-raios de Óxido de Zinco**. Tese (Doutorado) — Universidade Federal da Paraíba, Campina Grande, abril 1999.
- DIAS, M. B. B.; LIRA, G. R. S. **Levantamento do Estado da Arte dos Modelos de Previsão do Tempo de Vida Útil de Equipamentos Elétricos**. In: XIV Congresso de Iniciação Científica da UFCG, 2019, Campina Grande. Anais do XVI Congresso de Iniciação Científica da UFCG, 2019.
- DOORSAMY, W. & BOKORO, P. **Condition Monitoring of Metal-oxide Surge Arresters using Leakage Current Signature Analysis**. In: 20th International Conference on High Voltage Engineering, 2018.
- EHLERS, R. S. **Análise de Séries Temporais**. 2009. Disponível em: <<http://www.icmc.usp.br/ehlers/stemp/stemp.pdf>>. Acessado em 3 de março de 2018..
- FRONTIN, S. O. **Equipamentos de Alta Tensão – Prospecção e Hierarquização de Inovações Tecnológicas**. 1 ed., Brasília, Goya Editora LTDA, 2013..
- FUJIWARA, Y. et al. **Evaluation of surge degradation of metal oxide surge arrester**. IEEE Transactions on Power Apparatus and Systems, n. 4, p. 978-985, 1982.
- GEORGOFF, David M.; MURDICK, Robert G. **Manager's guide to forecasting**. Harvard Business Review, 1986.
- GOODFELLOW, I., BENGIO, Y., COURVILLE, A. **Deep Learning**. MIT Press, 2016.
- GREFF, K.; SRIVASTAVA, R.K.; KOUTNÍK, J.; STEUNEBRINK, B.R.; SCHMIDHUBER, J. **Lstm: a search space odyssey**. IEEE transactions on neural networks and learning systems, IEEE, 2016.
- GUPTA, T. K. **Application of zinc oxide varistors**. Journal of the American Ceramic Society, v. 73, n. 7, p. 1817-1840, 1990.
- HAN, Y. et al. **A decomposition method for the total leakage current of MOA based on multiple linear regression**. IEEE transactions on power delivery, v. 31, n. 4, p. 1422-1428, 2015.
- HAYKIN, S. **Neural Networks: a comprehensive foundation**. 2nd.ed. [S.l.]: Prentice Hall PTR, 1998.
- HEINRICH, C. & HINRICHSEN, V. **Diagnostics and monitoring of metal-oxide surge arresters in high-voltage networks-comparison of existing and newly developed procedures**. IEEE Transactions on Power Delivery, v. 16, n. 1, p. 138-143, 2001.
- HILEMAN, A. R. **Insulation Coordination for Power Systems**. New York, USA: Marcel Dekker, Inc., 1999.
- HINRICHSEN, V. **Monitoring of high voltage metal oxide surge arresters**. VI Jornadas Internacionales de Aislamiento Electrico, Bilbao, p. 22-23, 1997.
- HINRICHSEN, V. **Metal-Oxide Surge Arresters in High-Voltage Power Systems**. Fundamentals. Siemens AG, Erlangen, Germany, 2012.
- HOCHREITER, S.; SCHMIDHUBER, J. **Long short-term memory**. Neural Computation, v. 9, n. 8, p. 1735-1780, 1997.

- HONG, W. C. **Hybrid Advanced Techniques for Forecasting in Energy Sector**. Printed Edition of the Special Issue Published in *Energies*, 2018.
- HOANG, T. T. et al. **A novel differential particle swarm optimization for parameter selection of support vector machines for monitoring metal-oxide surge arrester conditions**. *Swarm and Evolutionary Computation*, v. 38, p. 120-126, 2018.
- IEC 60099-5. **Surge Arresters - Selection and Application Recommendations**. [S.l.], 2013.
- JANG, J. S. R. **ANFIS: Adaptative-Network-Based Fuzzy Inference System**. *IEEE Transactions on Systems Man and Cybernetics* vol. 23, 1993.
- KANNUS, K.; LAHTI, K. **Evaluation of the operational condition and reliability of surge arresters used on medium voltage networks**. *IEEE Transactions on Power Delivery*, v. 20, n. 2, p. 745-750, 2005.
- KHODSUZ, M.; MIRZAIE, M. **Monitoring and identification of metal-oxide surge arrester conditions using multi-layer support vector machine**. In: *IET Generation, Transmission & Distribution*, v. 9, n. 16, p. 2501-2508, July 2015.
- KIM, Y. S. **Failure Prediction of Metal Oxide Varistor Using Nonlinear Surge Look-up Table Based on Experimental Data**. *Transactions on Electrical and Electronic Materials*, v. 16, n. 6, p. 317-322, 2015.
- LIMA JÚNIOR, G. B. **Monitoramento de Para-raios de Óxido de Zinco em Campo**. Dissertação (Mestrado) - Universidade Federal de Campina Grande, Campina Grande, setembro 2014.
- LIRA, G. R. S.; COSTA, E. G.; FERREIRA, T. V. **Metal-oxide Surge Arrester Monitoring and Diagnosis by Self-Organizing Maps**. *Electric Power Systems Research*, v. 108, p. 315-321, March 2014.
- LIRA, J. G. A. **Sistema de Aquisição de Dados para Monitoramento e Diagnóstico Remoto das Condições de Para-raios de Óxido de Zinco**. Tese (Doutorado) - Universidade Federal de Campina Grande, Campina Grande, outubro 2007.
- LIRA, G. R. S. **Monitoramento de Para-raios de Óxido de Zinco com Base na Medição da Corrente de Fuga Total**. Tese (Doutorado) - Universidade Federal de Campina Grande, Campina Grande, julho 2012.
- LIU, K., FAN, Y. F., CHE, X. T., WANG, L., & JIANG, J. **A prediction techniques in resistive current measurement of metal oxide arrester**. In: *Power Engineering and Automation Conference (PEAM)*, 2012 IEEE. IEEE, 2012. p. 1-4.
- LUDWIG JÚNIOR, O. & MONTGOMERY, E. **Redes Neurais: Fundamentos e Aplicações com Programas em C**. 1 ed. Rio de Janeiro: Editora Ciência Moderna Ltda. 2007.
- LUNDQUIST, J., STENSTROM, L., SCHEI, A., & HANSEN, B. **New Method for Measurement of the Resistive Leakage Currents of Metal-Oxide Surge Arresters in Service**. *IEEE Trans. Power Del.*, v. 5, n. 4, p. 1811-1822, October 1990.
- LURGIO, S.A. **Forecasting Principles and Applications**. 1st Edition. Singapore: McGraw-Hill. 802p. 1998.

- MACÊDO, E. C. T. **Sistema de avaliação do nível de degradação de para-raios de óxido de zinco.** Dissertação (Mestrado) - Universidade Federal de Campina Grande, Campina Grande, março de 2010.
- MERCER, J. **Functions of positive and negative type and their connection with the theory of integral equations.** *Philosophical Transactions of the Royal Society A*, 209 (441–458): 415–446. 1909.
- MONTGOMERY, D. C.; JENNINGS, C. L; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting.** John Wiley & Sons, 2008.
- MORETTIN, P. A.; TOLOI, C. M. **Modelos para previsão de séries temporais.** Instituto de Matemática Pura e Aplicada. Rio de Janeiro, 1981.
- MOZELLI, L. A. **Controle fuzzy para sistemas takagi-sugeno: condições aprimoradas e aplicações.** Dissertação (Mestrado). Universidade Federal de Minas Gerais, Belo Horizonte, 2008.
- MYTTENAERE, A.; GOLDEN, B.; LE GRAND, B.; & ROSSI, F. **Mean absolute percentage error for regression models.** *Neurocomputing*, v. 192, p. 38-48, 2016.
- OLAH, C. **Understanding lstm networks.** 2015. Disponível em: <<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acesso em: 11 de julho de 2019.
- ORD, K. **Commentaries on the M3-competition. An. Introduction, some comments and scorecard.** *International Journal of Forecasting*. v. 17, p. 537-584, 2001.
- RINGLER, K. G. et al. **The energy absorption capability and time-to-failure of varistors used in station-class metal-oxide surge arresters.** *IEEE Transactions on Power Delivery*, v. 12, n. 1, p. 203-212, 1997.
- SANCHEZ, E. C. M. **Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência.** Dissertação (Mestrado). Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.
- SAKSHAUG, E. C. **A Brief History of AC Surge Arresters.** *IEEE Power Engineering Review*, v. 11, n. 8, p. 11–1, August 1991.
- SCHWITZKY, M. **Acuracidade dos Métodos de Previsão e sua Relação com o Dimensionamento dos Estoques dos Produtos Acabados.** Dissertação (Mestrado). Universidade Federal de Santa Catarina, 2001.
- SHIRAKAWA, S.; ENDO, F.; KITAJIMA, H.; KOBAYASHI, S.; KURITA, K.; GOTO, K.; SAKAI, M. **Maintenance of Surge Arrester by a Portable Arrester Leakage Current Detector.** *IEEE Trans. Power Del.*, v. 3, n. 3, p. 998–1003, July 1988.
- SMOLA, A. J.; SCH, B.; SCHÖLKOPF, B. **A Tutorial on Support Vector Regression.** *Statistics and Computing*, [S.l.], v.14, n.3, p.199–222, Aug. 2004.
- TRIDELTA, **Equipamento de diagnóstico para a avaliação do estado operacional de pára-raios óxido-metálicos - DIAG.** Tradução: ELOS, Jul. 2007.
- UDDINA, N. **Report on Condition Monitoring of Lightning Arresters.** Disponível em: <http://elocos.railnet.gov.in/MSG_ESC/Lightning_Arrestor.pdf> Acesso em: 05 novembro 2016.

- VAPNIK, V. N. **The Nature of Statistical Learning Theory**. New York, NY, USA: Springer-Verlag New York, Inc., 1995.
- VIDEIRA, A. G., 2011, **Desenvolvimento de Subsídios para Aplicação em Testes de Avaliação de Para-Raios de ZnO**. Dissertação de M.Sc., Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil.
- WEN, Y.; ZHOU, C. **A novel method for predicting the lifetime of MOV**. IEEE Transactions on Power Delivery, v. 19, n. 4, p. 1688-1691, 2004.
- WILKS, D. S. **Statistical Methods in the Atmospheric Sciences. International Geophysics Series. 2a**. Edição, Estados Unidos da América, Academic Press, v. 91, 2006. 627 p.
- XAVIER, T. S. **Previsão de Séries Temporais Utilizando Modelos Clássicos e Redes Neurais Artificiais**. Trabalho de Conclusão de Curso — Universidade Federal de Campina Grande, 2018.
- YUANFANG, W.; XIANGLIAN, Y.; CHUN, L. **A method for the lifetime prediction of MOV**. In: Electrical Insulating Materials, 2001. Proceedings of 2001 International Symposium on IEEE, 2001. p. 757-760.
- ZADEH, L., **Fuzzy Sets, Information and Control**. IEEE Transactions on Systems, Man and Cybernetics 8: 338-353, 1965.
- ZHAO, T.; LI, Q.; QIAN, J. **Investigation on Digital Algorithm for On-Line Monitoring and Diagnostics of Metal Oxide Surge Arrester Based on an Accurate Model**. IEEE Transactions on Power Delivery, v. 20, n. 2, p. 751-756, April 2005.
- ZHOU L.; XIE L.; TONG X. J. **Recursive Neural Networks and its Application in Forecasting the State of Electric Power Equipment**. Sixth International Conference on Machine Learning and Cybernetics, Hong Kong, 2007.