

Aplicação de Redes Neurais Artificiais para Estimação de Indicadores de Segurança Estática e Dinâmica de Sistemas Elétricos de Potência

Daniela C. R. Souza*. Vitor H. Ferreira**
Carlos A. S. Neto***

*Universidade Federal Fluminense, Niterói, RJ 27255-125
BR; e-mail: coelhodaniela@id.uff.br

**Universidade Federal Fluminense, Niterói, RJ 27255-125
BR; e-mail: vhferreira@id.uff.br

***Operador Nacional do Sistema Elétrico, Rio de Janeiro, RJ 20211-160,
BR; e-mail: cneto@ons.org.br

Abstract: Nowadays, with the increase of fear of blackout events due to society's increased dependence on electricity, the development of studies related to the power systems security analysis is one of the main activities to be carried out within the scope of planning and operation of electrical grids. Thus, this subject has been debated in the literature for a long period of time and with the advancement of computational power, lots of studies are developed using artificial intelligence techniques for the prediction of indicators related to the power systems security analysis. In this context, this article presents the development of a model, using artificial neural networks, which will work together with power system analysis software for prediction safety indicators, static and dynamic, of electrical power systems.

Resumo: Atualmente, com o maior receio de ocorrências de blecautes em função do aumento da dependência da energia elétrica pela sociedade, o desenvolvimento de estudos relacionados à segurança dos sistemas elétricos de potência desponta como uma das principais atividades a serem realizadas no âmbito do planejamento e da operação dos sistemas elétricos. Em função disso, este assunto tem sido amplamente debatido na literatura e com o avanço do poder computacional, cada vez mais autores propõem a utilização de técnicas de inteligência artificial para a previsão de indicadores relacionados à segurança dos Sistemas Elétricos de Potência. Neste contexto, este artigo apresenta o desenvolvimento de um modelo, utilizando redes neurais artificiais, que irá atuar em conjunto com *softwares* de análise de sistema de potência para a previsão de indicadores de segurança estática e dinâmica de sistemas elétricos de potência.

Keywords: Power System Security; Electrical System Operation; Organon; Machine Learning; Artificial Neural Networks; Bayesian Training; Levenverg-Marquardt.

Palavras-chaves: Análise de Segurança de Sistema; Operação de Sistemas Elétricos; Organon; Aprendizado de Máquinas; Redes Neurais Artificiais; Treinamento Bayesiano; Levenberg-Marquardt.

1. INTRODUÇÃO

Atualmente, com a maior dependência da sociedade pela energia elétrica, e em função disso o maior receio de blecautes como os de 2003 nos Estados Unidos e Canadá, e 2009 e 2018 que ocorreram no Brasil, se tornou fundamental o desenvolvimento de ferramentas, rápidas e confiáveis, para a análise de segurança dos Sistemas Elétricos de Potência (SEP) (Li et al., 2020). Dessa forma, a avaliação de segurança dos SEPs avança como uma das principais atividades realizadas durante o planejamento e a operação desses sistemas (El-Amin and Al-Shams, 1997). É válido destacar que, o desenvolvimento dessa atividade não é trivial, dado a frequente mudança dos pontos de operação, devido a falhas, mudanças topológicas e nas condições de carga (Shahidehpour et al., 2005).

A análise de segurança pode ser definida como o conjunto de métodos e estudos realizados com o objetivo de determinar, com base em critérios de segurança previamente definidos, o

estado operativo da rede, ou seja, se ela está segura ou não, sendo desenvolvido através desses resultados instruções operativas a serem usadas na operação em tempo real.

De forma geral, as principais avaliações realizadas durante os estudos de análise de segurança dos SEPs são: a avaliação estática e a avaliação dinâmica, sendo parte da avaliação dinâmica a análise de segurança transitória (Sterpu et al., 2006). A avaliação estática tem como objetivo determinar se um ponto de operação se encontra seguro ou não em regime permanente. Para isto, é verificado se o nível de tensão em todas as barras do determinado sistema encontra-se dentro do limite aceitável e se o fluxo das linhas de transmissão e transformadores encontram-se dentro de seus respectivos limites térmicos. Destaca-se que a análise de contingência também pode ser realizada nessa avaliação (Sterpu et al., 2006).

A avaliação dinâmica visa determinar a capacidade do sistema de passar de um determinado ponto operativo a outro, após a ocorrência de uma perturbação. Diversos estudos têm sido

desenvolvidos a respeito dessa avaliação, principalmente para auxiliar a operação em tempo real (Nohara et al., 2009).

Por fim, a avaliação transitória destina-se a verificar o comportamento do sistema poucos instantes após o acontecimento da perturbação. Essa análise indica se a rede será capaz de eliminar a perturbação sem comprometer o seu bom funcionamento (Sterpu et al., 2006).

Logo, pode-se entender a avaliação de segurança dos SEPs como um processo de análise dos impactos da ocorrência de determinadas contingências no sistema, tendo como benefícios dessa atividade o aumento da confiabilidade e a melhor utilização dos recursos eletroenergéticos do sistema (Jardim et al., 2006; Silva and Schimidt, 2016).

Em decorrência da importância do tema para a sociedade, diversas pesquisas têm sido desenvolvidas durante as últimas décadas, como a revisão bibliográfica sobre análise de segurança, estática e dinâmica, de sistemas elétricos de potência realizada por (Balu et al., 1992), a pesquisa para a criação de uma ferramenta unificada para análise de segurança em regime permanente e dinâmico proposto por (Popović, 1989), e o estudo desenvolvido por (Ghafurian and Berg, 1981) que visa a criação de um indicador de análise de segurança calculado através dos estudos de fluxo de potência e curto-circuito. Além disso, diversos trabalhos podem ser encontrados na literatura como métodos de domínio no tempo, ajuste de curva e critério das áreas iguais, para a classificação da estabilidade do sistema (Sobbouhi and Vahedi, 2021; Tan and Zivanovic, 2007; Wang et al., 2014). Recentemente, com o avanço do poder computacional, diversas pesquisas têm sido desenvolvidas utilizando técnicas de aprendizado de máquinas, como por exemplo as Redes Neurais Artificiais (do inglês *Artificial Neural Network*) (Alimi et al., 2020; Amjady, 2003; Aydin and Gumus, 2020; Calma and Pacis, 2021; Hagmar et al., 2021; Lotufo et al., 2007; Sawhney and Jeyasurya, 2006; Veerasamy et al., 2021).

Os estudos de segurança estática e dinâmica são realizados utilizando *softwares* de simulação de sistemas elétricos de potência considerando diversos cenários de rede e de operação. Diante da miríade de possibilidades existentes, é indicado o desenvolvimento de ferramentas que sejam capazes de extrair conhecimento das diversas simulações realizadas e que seriam descartadas ao final do processo. Isto posto, o presente trabalho tem como objetivo a criação de um modelo utilizando técnicas de aprendizado de máquina (do inglês *Machine Learning*), mais especificamente as Redes Neurais Artificiais (RNA), com o intuito de extrair conhecimento das diversas simulações, realizando uma pré análise e apresentando ao usuário indicadores que o apoiem sobre o estado operativo do SEP em análise. Os cenários simulados pelo *software* utilizado (seção 2) serão considerados para o treinamento dos modelos para estimação dos indicadores, dando origem a um sistema de inferência que permite a projeção de cada indicador sem a necessidade de uso do simulador na operação em tempo real.

É válido destacar que a ferramenta desenvolvida no presente artigo poderá ser utilizada nas atividades relativas à operação em tempo real, isto é, dentro dos inúmeros centros de operação. O modelo proposto pode ser acoplado a qualquer

software de análise de segurança, não sendo estritamente dependente de somente um tipo de *software*, sendo necessária somente a disponibilização dos resultados das simulações realizadas para treinamento *offline* dos modelos. Destaca-se que quando comparado ao tempo de simulação dos *softwares* de análise de segurança, a ferramenta desenvolvida será capaz de apresentar resultados de forma mais ágil, possibilitando o uso dos simuladores somente para análises mais complexas e detalhadas a respeito de determinados pontos de operação apontados como inseguros pelo modelo desenvolvido.

2. ANÁLISE DE SEGURANÇA NO SISTEMA ELÉTRICO BRASILEIRO

No Brasil, o Operador Nacional do Sistema Elétrico (ONS) é o órgão responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN) e pelo planejamento da operação dos sistemas isolados do país, sob a fiscalização e regulação da Agência Nacional de Energia Elétrica (ANEEL) (“ONS - Operador Nacional do Sistema Elétrico,” 2021). Esse órgão define em seus documentos normativos, procedimentos de rede, os critérios a serem atendidos durante a operação do SIN (ONS, 2020).

O programa Organon é um *software* desenvolvido para análise e avaliação de segurança de sistemas elétricos de potência, sendo adequado para o ambiente de planejamento durante os estudos de análise de regime permanente e contingências, bem como análises dinâmicas como em estudos das oscilações eletromecânicas, e para o ambiente de operação em tempo real dos SEPs (Neto et al., 2011).

Uma das principais vantagens da utilização do *software* Organon consiste no cálculo da região de segurança, sendo essa região definida como a exploração de pontos de operação, a partir da condição atualizada da operação, indicando violações de limites e critérios operativos. Sua apresentação ao usuário é realizada em forma de nomogramas (gráficos bidimensionais da região de segurança), como exposto na Fig. 1. Os nomogramas têm como objetivo informar sobre a segurança estática e dinâmica de um determinado ponto de operação do SEP. As referências (Neto et al., 2011; ONS, 2020) apresentam maiores detalhes sobre o cálculo e a definição dessa região.




Fig. 1 - Nomograma e suas definições (ONS, 2020)

Apesar do elevado esforço computacional necessário para a realização de estudos mais detalhados, isto é, com o maior número de direções e contingências a serem analisadas pelo *software* Organon, em função da elevada confiança desse *software* ainda é indicada sua utilização na operação dos SEPs (de Oliveira et al., 2003). Logo, é uma boa estratégia o desenvolvimento de ferramentas que sejam capazes de trabalhar em conjunto com o Organon.

3. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais foram criadas com o intuito de emular as atividades realizadas pela mente humana, dado a sua capacidade de lidar com problemas de forma não linear (Haykin and Engel, 2001). De forma geral, as redes neurais têm o objetivo de realizar o processamento de sinais paralelamente distribuídos, desenvolvido por unidades de conhecimento que são denominados neurônios (Amaral, 2019). As redes neurais artificiais são formadas, basicamente, por três tipos de elementos, que são: os pesos, que é análogo ao conjunto de sinapses da mente humana; os somadores, que são responsáveis pela soma dos sinais de entrada, e, por fim, as funções de ativação que garantem a capacidade do modelo em tratar problemas não lineares.

As principais vantagens de utilização dos modelos neurais são (Barbosa, 2020; Ferreira, 2008; Martins, 2018):

- Não-linearidade: para o caso mais comumente utilizado, em que a função de ativação dos neurônios da camada oculta é não-linear, o modelo neural resultante da interconexão destas unidades mais simples apresenta considerável grau de não-linearidade. No entanto, esta vantajosa característica pode ser prejudicial na presença de dados ruidosos, problema que será abordado ao longo desta seção.
- Mapeamento entrada-saída: a partir de um conjunto de pares, entrada e saída, as redes neurais realizam um mapeamento destes dados, sem a necessidade de desenvolvimento de modelos matemáticos que descrevem a dinâmica do processo.
- Adaptabilidade: estes modelos apresentam elevada capacidade de adaptação a mudanças nas condições do ambiente para o qual a rede foi treinada para operar. Para tal, basta retreinar o modelo, incluindo no conjunto de treinamento os padrões referentes às novas condições operacionais.
- Implementação simples: já que os modelos *feedforward* podem ser vistos como grafos orientados, a implementação destas estruturas é extremamente simples quando comparada com o grau de complexidade dos modelos que podem ser gerados.

As RNAs são modelos capazes de aproximar qualquer função contínua com precisão arbitrária, desde que seja definido um número correto de neurônios em sua camada escondida (Zhang et al., 1998). Além disso, outros parâmetros, como o conjunto de pesos (\underline{w}) e os hiperparâmetros α e β , descritos a seguir no treinamento Bayesiano, devem ser ajustados durante o desenvolvimento desse tipo de modelo, o que representa um grande desafio durante a modelagem (Ferreira and da Silva, 2007).

Logo, com o objetivo de tratar as questões citadas anteriormente, o presente trabalho utilizará durante o desenvolvimento dos modelos a técnica de validação cruzada (do inglês *Cross Validation*) *K-fold* para a escolha do número de neurônios na camada oculta do modelo e os seguintes

algoritmos de treinamento: treinamento Bayesiano aplicado as redes perceptrons de múltiplas camadas (do inglês *Multi Layer Perceptrons - MLPs*) (Bishop, 2011) e algoritmo de treinamento proposto por *Levenberg-Marquardt* (LM). Dado que o treinamento Bayesiano garante o controle de complexidade de forma intrínseca (Ferreira, 2008), será realizado uma comparação dos resultados deste modelo em relação ao uso da técnica de validação cruzada (*K-fold*), para seleção do número de neurônios na camada escondida, com o algoritmo de treinamento proposto por *Levenberg-Marquardt*.

3.1 Treinamento Bayesiano Aplicado às Redes Neurais Artificiais

Ao contrário dos demais treinamentos, que apresentam como objetivo minimizar o erro quadrático médio, o objetivo do treinamento sob a concepção Bayesiana consiste em encontrar o conjunto de pesos \underline{w} que maximize a probabilidade a posteriori $p(\underline{w}|D,X)$, apresentado pela equação (1), sendo D o conjunto de padrões de saída disponíveis para o treinamento e X o conjunto com as respectivas entradas:

$$p(\underline{w} | X, D) = p(D | X, \underline{w}) \frac{p(\underline{w})}{p(D, X)} \quad (1)$$

Pode-se definir $p(\underline{w}|D,X)$ como a função de verossimilhança, $p(\underline{w})$ a probabilidade a priori do vetor de pesos \underline{w} e $p(D,X)$ a probabilidade de ocorrência de D dado X .

Uma vez que $p(D,X)$ independe do vetor \underline{w} e não irá impactar no problema de otimização, será assumido que essa probabilidade é um fator de normalização e suprimida das demais apresentações. Logo, o presente objetivo consiste em especificar as probabilidades $p(D|X, \underline{w})$ e $p(\underline{w})$.

Assumindo como premissa que o vetor de pesos \underline{w} deve apresentar valores próximos a zero, com o objetivo de mitigar a saturação durante o treinamento. Será adotado que o conjunto de pesos segue uma distribuição normal com média nula e matriz de covariância proporcional à matriz identidade (αI), conforme apresentado pela equação (2) (Ferreira and da Silva, 2007; Martins et al., 2018).

$$p(\underline{w}) = \frac{1}{\sqrt{\frac{2\pi}{\alpha}}^M} e^{-\frac{\alpha}{2} \sum_{i=1}^M w_i^2} \quad (2)$$

Além disso, assumindo que os erros são independentes e distribuídos identicamente segundo uma distribuição normal com média nula e variância $1/\beta$, conforme apresentado na equação (3).

$$p(D | X, \underline{w}) = \frac{1}{\sqrt{\frac{2\pi}{\beta}}^N} e^{-\frac{\beta}{2} \sum_{i=1}^N (d^{(k)} - f(x^{(k)}, \underline{w}))^2} \quad (3)$$

Definido a função de verossimilhança $p(D|X, \underline{w})$ e a probabilidade a priori do vetor de pesos \underline{w} $p(\underline{w})$, pode-se especificar a função a ser otimizada, apresentada pela equação (4):

$$\begin{aligned} \max_{\underline{W}} p(\underline{W} | X, D) &= \max_{\underline{W}} p(D | X, \underline{W}) p(\underline{W}) = \\ &= \max_{\underline{W}} \frac{1}{\sqrt{\frac{\alpha\beta}{2\pi}^{M+1}}} e^{-\left[\frac{\beta}{2} \sum_{i=1}^N \{d(k) - f[x(k), \underline{W}]\}_i^2 + \frac{\alpha}{2} \sum_{j=1}^M W_j^2\right]} \end{aligned} \quad (4)$$

Logo, para maximizar $p(D/X, \underline{W})$ é necessário é minimizar o expoente da expressão (4), ou seja:

$$\begin{aligned} \min_{\underline{W}} \{S(\underline{w})\} \\ S(\underline{w}) = \frac{\beta}{2} \sum_{i=1}^N \{d(k) - f[x(k), \underline{W}]\}_i^2 + \frac{\alpha}{2} \sum_{j=1}^M W_j^2 \end{aligned} \quad (5)$$

Até o momento os hiperparâmetros α e β foram adotados como conhecidos, contudo, essas variáveis devem ser adicionadas ao problema de otimização e calculadas. As referências (A. M. Barbosa and H. Ferreira, 2020; Ferreira, 2008; Martins, 2018) apresentam maiores detalhes sobre o procedimento para esse cálculo.

Destaca-se que, a equação (5) apresenta a métrica a ser otimizada durante o treinamento Bayesiano. Com a minimização da função $S(w)$ é encontrado um ponto de equilíbrio entre o ajuste do modelo aos dados disponíveis e o controle de magnitude dos pesos, fazendo com que no modelo não seja visualizado o problema de *overfitting/underfitting* e garantindo que os mapeamentos suaves possam ser gerados (Barbosa, 2020).

3.2 Algoritmo Levenberg-Marquardt

Em contrapartida ao algoritmo de treinamento Bayesiano supracitado, o algoritmo de *Levenberg-Marquardt* possui como objetivo a minimização do erro quadrático médio entre a resposta do modelo e os dados reais (Sadeghkhan et al., 2009). Esse algoritmo tem sido amplamente utilizado na literatura uma vez que pode ser interpretado como uma variação do método Gradiente Descendente (Arif et al., 2009), e também, em função de seu rápido tempo de convergência (Varshney et al., 2012).

A regra de atualização dos pesos da RNA, que pode ser entendida como a regra de aprendizagem do modelo, no algoritmo de treinamento proposto por *Levenberg-Marquardt* é baseada na aceleração do treinamento em relação a determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, conforme apresentado pela equação (6) (Abreu et al., 2012):

$$\underline{W}(k+1) = \underline{W}(k) - [J^T(\underline{W})J(\underline{W}) + \mu_k I]^{-1} J^T(\underline{W})e(\underline{W}) \quad (6)$$

Onde, o \underline{W} é o vetor de pesos da RNA, J é a matriz jacobiana, I é a matriz identidade, μ_k é o fator de amortecimento do método e $e(\underline{W})$ é o vetor de erro.

3.3 Validação Cruzada

Na literatura, basicamente, são encontradas quatro técnicas principais de validação cruzada, que são: *Hold-out*, *K-fold*, *Leave-one-out*, *Bootstrap*. Neste trabalho será utilizado o

método de validação cruzada *K-fold*, que consiste em dividir o conjunto de dados em K partes iguais (d_1, d_2, \dots, d_k). O processo é constituído por K iterações, com k variando de 1 até K , onde em cada uma dessas iteração a amostra de validação será representada pelo conjunto d_k . Dessa forma, a amostra de treino será constituída pelas demais partes, ou seja, todos os dados serão utilizados no treinamento, a exceção daqueles que fazem parte do conjunto d_k .

Portanto, o método *K-fold*, pode ser representado pela equação (7).

$$kfK = \frac{1}{K} \sum_{k=1}^K \frac{1}{m_k} \sum_{i=1}^{m_k} L(y_{ik}, f_{(-k)}(x_{ik})) \quad (7)$$

Onde, $\hat{f}_{(-k)}(x_{ik})$ criado como a amostra de treino de d_k , $k=1$ até K , sendo o preditor avaliado nas observações da amostra de teste.

Destaca-se que o número de padrões em cada conjunto $d_{(K)}$ diminui quanto maior for o valor de K (Borra and Di Ciaccio, 2010), logo, para K muito elevado acaba aumentando o custo computacional da técnica, além de uma amostra de teste pequena, o que aumenta a variância. Na literatura se discute qual valor de K seria o ideal, sendo os mais utilizados, dois, três, cinco e dez. Neste trabalho será utilizado $K=10$. A referência (Cunha, 2019) cita que os estudos com $K=10$ tem os melhores desempenhos, (Borra and Di Ciaccio, 2010) e (Kim, 2009) também utilizam em seus trabalhos $K=10$.

3.4 Programa Desenvolvido

Com a finalidade de garantir a melhor reprodutibilidade da metodologia desenvolvida, a presente seção possui como objetivo descrever de forma sucinta como encontra-se estruturado o modelo desenvolvido. A Fig. 2 apresenta o macrofluxo do programa, sendo cada uma das etapas descritas no próximo parágrafo.

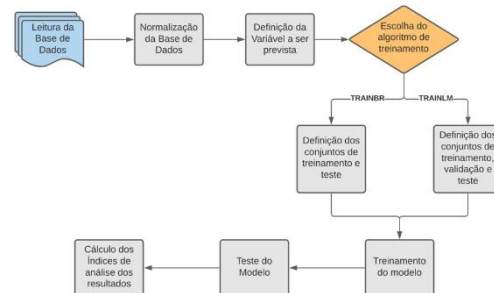


Fig. 2 – Macrofluxo do Modelo Desenvolvido

A primeira etapa consiste em realizar a leitura de todas as variáveis utilizadas no modelo. Em seguida, na segunda etapa, devido ao uso de unidades e valores distintos é realizado a normalização dos dados. Na terceira etapa é definido qual variável será prevista pelo modelo. Após a realização da terceira etapa, é definido qual metodologia será utilizada para o treinamento do modelo, sendo a partir dessa definição separado o conjunto de dados em treinamento e testes quando utilizado o treinamento Bayesiano e treinamento, validação e testes quando aplicado o treinamento proposto por *Levenberg-Marquardt*. Na sexta etapa, é aplicada a metodologia de

treinamento no conjunto de dados definidos anteriormente e com o modelo treinado o conjunto de teste é utilizado no modelo com o objetivo de averiguar sua assertividade. Por fim, as estatísticas de avaliações dos resultados são calculadas e avaliadas pelo usuário.

Destaca-se que a próxima seção apresenta maiores detalhes sobre todos os dados utilizados para o desenvolvimento da metodologia.

4. RESULTADOS

Nesse item, serão detalhados os resultados alcançados ao se aplicar as metodologias propostas. Três variáveis serão estimadas: o índice de estabilidade, o índice de violação de tensão e o índice de violação de carregamento. Além disso, será avaliado dois tipos de estratégia para o desenvolvimento do modelo proposto. A primeira delas consiste na utilização do algoritmo de treinamento Bayesiano que apresenta de maneira intrínseca ao método o controle de complexidade. A segunda estratégia utiliza o algoritmo de treinamento proposto por *Levenberg-Marquardt*, em conjunto com a técnica de validação cruzada, *K-fold*, para o controle de complexidade. Destaca-se que em ambos os métodos o número de neurônios na camada escondida irá variar entre um e 25, sendo, o melhor modelo escolhido de acordo com o menor erro para o conjunto de treinamento quando utilizado o treinamento Bayesiano e o menor erro para o conjunto de validação quando utilizado o treinamento proposto por *Levenberg-Marquardt*.

O índice de estabilidade (do inglês *Stability Index - STBLDX*) possui como objetivo caracterizar a condição de estabilidade do sistema frente a perturbação simulada. Já o índice de violação de tensão (do inglês *Voltage Violation - VVIO*) indica a pior violação de tensão monitorada nas barras do sistema, assumindo valores negativos quando não existem violações de tensão e valores positivos quando há alguma violação de tensão nas barras. Por fim, o índice de carregamento (do inglês *Thermal Violation - TVIO*) informa ao usuário sobre o maior carregamento observado nos equipamentos monitorados: quando superior a 100 este índice indica violação de carregamento no circuito.

É importante salientar que os dados utilizados para o desenvolvimento e teste do modelo proposto são oriundos do *software* Organon. Para a modelagem, foram utilizados 1372 padrões, sendo 20% desse conjunto, 274 padrões, aplicado durante a etapa de teste do modelo e os demais dados utilizados para o treinamento. Ressalta-se que os 274 padrões escolhidos para o conjunto de teste foram selecionados de forma aleatória, sendo esse conjunto mantido fixo durante os testes de ambos os modelos propostos.

Os dados de entrada utilizados no modelo foram: Distância, Contingência, Direção, Geração 1, Geração 2 e Geração 3. Essas variáveis apresentam as seguintes definições (ONS, 2020):

- Distância: equivale a distância Euclidiana entre um novo ponto de operação e o ponto de operação de partida. Essa distância é calculada em relação a alteração dos grupos de geração 1 e 2, tendo como unidade MW;

- Contingência: lista de contingência pré-estabelecida para a simulação da região de segurança;
- Direção: representa o deslocamento do Ponto de Operação em decorrência da alteração dos despachos de geração;
- Geração: grupos de usinas onde são efetuadas alterações em seu despacho.

No presente trabalho, foram utilizadas como gerações máquinas das regiões Norte (Geração 1), Nordeste (Geração 2) e Sudeste (Geração 3). As contingências foram focadas na interligação Norte-Nordeste e algumas linhas de transmissão da região Nordeste.

Torna-se valido frisar que os resultados alcançados durante o treinamento e teste do modelo serão avaliados através de três métodos: o erro (equação (8)), o erro absoluto médio (equação (9)) e pelo coeficiente de determinação (R^2) (equação (10)):

$$E = V_f - V_p \quad (8)$$

$$E_{am} = \sum_{i=1}^N \frac{|V_i - P_i|}{N} \quad (9)$$

$$R^2 = \rho(X, Y)\rho(X, Y) \quad (10)$$

Onde, E é o Erro, V_f é o valor verificado, V_p é o valor previsto, E_{am} é o Erro Absoluto Médio, V_i é o valor verificado da i -ésima amostra, P_i é o valor previsto da i -ésima amostra, N é o número de padrões e R^2 é o Coeficiente de Determinação e $\rho(X, Y)$ é o Coeficiente de Correlação de Person.

A seguir, os resultados serão apresentados de forma gráfica, sendo visto através desses gráficos a previsão originada pelos modelos desenvolvidos, os valores verificados originais e o desvio entre os valores verificados e os previstos.

As figuras 3, 4 e 5 expõem os resultados alcançados ao se utilizar o método de treinamento Bayesiano, enquanto as figuras 6, 7 e 8 ilustram os resultados ao se utilizar o algoritmo de treinamento proposto por *Levenberg-Marquardt*.




Fig. 3 - Análise do Índice de Estabilidade (treinamento Bayesiano)




Fig. 4 - Índice de Violação de Tensão (treinamento Bayesiano)



Fig. 5 - Índice de Violação de Carregamento (treinamento Bayesiano)




Fig. 6 - Índice de Estabilidade com a utilização de *K-fold* (Levenberg-Marquardt)




Fig. 7 - Índice de Violação de Tensão com a utilização de *K-fold* (Levenberg-Marquardt)




Fig. 8 - Índice de Violação de Carregamento com a utilização de *K-fold* (Levenberg-Marquardt).

Para uma melhor comparação do leitor, será apresentado de maneira resumida, através das tabelas 1 e 2, os resultados alcançados durante os testes dos modelos, para cada uma das formas de treinamento utilizados. Sendo visto nestas tabelas o número de neurônios utilizados em cada um dos modelos, o desvio médio absoluto, o coeficiente de correlação de Pearson e o tempo de simulação (tempo total de execução do modelo, que é igual ao tempo de treinamento mais o tempo de teste do modelo).

Tabela 1 - Tabela Resumo dos Resultados (Treinamento Bayesiano)

Método de Treinamento Bayesiano				
	Tempo de Simulação (s)	Número de Neurônios	Erro Médio Absoluto	R ²
STBLDX	232,109	24	0,0915	0,6752
VVIO	320,110	21	0,0203	0,7540
TVIO	292,596	21	1,0059	0,8398

Tabela 2 - Tabela Resumo dos Resultados (Treinamento proposto por Levenberg-Marquardt)

Método de Treinamento: <i>Levenberg-Marquardt</i>				
	Tempo de Simulação (s)	Número de Neurônios	Erro Médio Absoluto	R ²
STBLDX	1.172,667	12	0,1007	0,5919
VVIO	1.121,559	14	0,0332	0,3463
TVIO	1.180,882	7	1,6089	0,5910

Destaca-se que em todos os casos analisados, foi observado o melhor desempenho no modelo construído utilizando o algoritmo de treinamento Bayesiano. Além disso, é possível observar um menor tempo de simulação ao se utilizar esse algoritmo.

5. CONCLUSÃO

Através do presente trabalho pode-se observar o bom desempenho das redes neurais artificiais ao serem aplicadas ao problema de estimação de indicadores utilizados para análise de segurança dos sistemas elétricos de potência.

Através dos resultados obtidos, verifica-se que a ferramenta desenvolvida apresentou bons resultados quando utilizada para estimar os indicadores de segurança, o que viabiliza sua utilização nas rotinas referentes a análise de segurança dentro dos centros de controle. Além do bom resultado alcançado, observa-se que a ferramenta apresenta um bom desempenho em relação ao seu tempo de simulação, isto é, a ferramenta possui a capacidade de se adaptar e gerar resultados quando novos padrões são apresentados com o tempo médio de quatro minutos (treinamento Bayesiano), sendo este mais um ponto favorável à sua utilização dentro das salas de controle.

Destaca-se que, o algoritmo de treinamento Bayesiano despontou como a melhor forma de treinamento para as Redes Neurais Artificiais quando comparado ao algoritmo de treinamento proposto por *Levenberg-Marquardt*, que apresentou um pior desempenho e um maior tempo de simulação.

Torna-se válido frisar que, apesar do modelo proposto nesse trabalho ter sido desenvolvido utilizando dados do *software* Organon, o presente modelo poderá ser utilizado em conjunto com outras ferramentas de análise de segurança, não se tornando assim, dependente unicamente deste *software*.

Além dos fatos previamente mencionados observa-se uma vasta possibilidade de desenvolvimento de trabalhos futuros como por exemplo: o desenvolvimento de uma ferramenta que seja capaz de interpretar os resultados alcançados e informar ao usuário o estado operativo do SEP; a implementação de técnicas que sejam capazes de garantir a melhor escolha das variáveis a serem utilizadas como entradas nas Redes Neurais Artificiais; e por fim, torna-se indicado também a utilização de índices estatísticos que sejam capazes de quantificar as incertezas durante o processo de previsão em função da complexidade do problema.

Portanto, através do presente trabalho, observa-se uma possível aplicação das RNAs em conjunto com *softwares* de

análise de segurança para a estimação de indicadores de segurança, sendo alcançados bons resultados no que tange ao desempenho do modelo e em seu tempo de simulação.

AGRADECIMENTOS

Agradeço ao professor Vitor Hugo, ao Engenheiro Carlos Alberto da Silva Neto e a Universidade Federal Fluminense

REFERÊNCIAS

- A. M. Barbosa, D., H. Ferreira, V., 2020. Inferência Bayesiana Aplicada a MLPs para Previsão Probabilística de Carga Semanal, in: Anais Do Simpósio Brasileiro de Sistemas Elétricos 2020. Presented at the Simpósio Brasileiro de Sistemas Elétricos - SBSE2020, sbabra. <https://doi.org/10.48011/sbse.v1i1.2260>
- Abreu, T., Paredes, M., Araujo, K.A.M., Lopes, M.L.M., Lotufo, A.D.P., 2012. Previsão de Cargas Elétricas através de um Modelo Híbrido de Regressão com Redes Neurais Artificiais. SBSE 6.
- Alimi, O.A., Ouahada, K., Abu-Mahfouz, A.M., 2020. A Review of Machine Learning Approaches to Power System Security and Stability. IEEE Access 8, 113512–113531. <https://doi.org/10.1109/ACCESS.2020.3003568>
- Amaral, H.L.M. do, 2019. Desenvolvimento de uma Nova Metodologia para a Previsão do Consumo de Energia Elétrica de Curto Prazo Utilizando Redes Neurais Artificiais e Decomposição de Séries Temporais (Tese). USP, São Paulo.
- Amjady, N., 2003. Dynamic voltage security assessment by a neural network based method. Electric Power Systems Research 66, 215–226. [https://doi.org/10.1016/S0378-7796\(03\)00048-8](https://doi.org/10.1016/S0378-7796(03)00048-8)
- Arif, J., Ray Chaudhuri, N., Ray, S., Chaudhuri, B., 2009. Online Levenberg-Marquardt algorithm for neural network based estimation and control of power systems, in: 2009 International Joint Conference on Neural Networks. Presented at the 2009 International Joint Conference on Neural Networks (IJCNN 2009 - Atlanta), IEEE, Atlanta, Ga, USA, pp. 199–206. <https://doi.org/10.1109/IJCNN.2009.5179071>
- Aydin, F., Gumus, B., 2020. Study of Different ANN Algorithms for Voltage Stability Analysis, in: 2020 Innovations in Intelligent Systems and Applications Conference (ASYU). Presented at the 2020 Innovations in Intelligent Systems and Applications Conference (ASYU), IEEE, Istanbul, Turkey, pp. 1–5. <https://doi.org/10.1109/ASYU50717.2020.9259817>
- Balu, N., Bertram, T., Bose, A., Brandwajn, V., Cauley, G., Curtice, D., Fouad, A., Fink, L., Lauby, M.G., Wollenberg, B.F., Wrubel, J.N., 1992. On-line power system security analysis. Proc. IEEE 80, 262–282. <https://doi.org/10.1109/5.123296>
- Barbosa, D.A.M., 2020. Analytics e Machine Learning para a Previsão Automática de Carga Horária e Semanal (Dissertação). Universidade Federal Fluminense, Niterói.
- Bishop, C.M., 2011. Pattern Recognition and Machine Learning. Springer, New York.
- Borra, S., Di Ciaccio, A., 2010. Measuring the Prediction Error. A Comparison of Cross-Validation, Bootstrap and Covariance Penalty Methods. Computational Statistics & Data Analysis 54, 2976–2989. <https://doi.org/10.1016/j.csda.2010.03.004>
- Calma, E.R.B., Pacis, M.C., 2021. Artificial Neural Network-based Voltage Stability Analysis of Power Transmission Networks with Distributed Generation using Phasor Measurement Unit Synthetic Data, in: 2021 IEEE 12th Control and System Graduate Research Colloquium (ICSGRC). Presented at the 2021 IEEE 12th Control and System Graduate Research Colloquium (ICSGRC), IEEE, Shah Alam, Malaysia, pp. 1–6. <https://doi.org/10.1109/ICSGRC53186.2021.9515237>
- Cunha, J.P.Z., 2019. Um Estudo Comparativo das Técnicas de Validação Cruzada Aplicadas a Modelos Mistos (Dissertação). Universidade de São Paulo, São Paulo.
- de Oliveira, E.N., Padilha, A., Minussi, C.R., 2003. Use of Transient Stability Indices to Dynamic Security Assessment. IEEE Latin Am. Trans. 1, 27–33. <https://doi.org/10.1109/TLA.2003.1468616>
- El-Amin, I.M., Al-Shams, A.-A.M., 1997. Transient stability assessment using artificial neural networks. Electric Power Systems Research 40, 7–16. [https://doi.org/10.1016/S0378-7796\(96\)01124-8](https://doi.org/10.1016/S0378-7796(96)01124-8)
- Ferreira, V.H., 2008. Desenvolvimento de Modelos Neurais Autônomos para a Previsão de Carga Elétrica (Teses). Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Ferreira, V.H., da Silva, A.P.A., 2007. Toward Estimating Autonomous Neural Network-Based Electric Load Forecasters. IEEE Trans. Power Syst. 22, 1554–1562. <https://doi.org/10.1109/TPWRS.2007.908438>
- Ghafurian, A., Berg, G.J., 1981. A stability measure for use in power system transient stability studies. Electric Power Systems Research 4, 121–128. [https://doi.org/10.1016/0378-7796\(81\)90015-8](https://doi.org/10.1016/0378-7796(81)90015-8)
- Hagmar, H., Tong, L., Eriksson, R., Tuan, L.A., 2021. Voltage Instability Prediction Using a Deep Recurrent Neural Network. IEEE Trans. Power Syst. 36, 17–27. <https://doi.org/10.1109/TPWRS.2020.3008801>
- Haykin, S., Engel, P.M., 2001. Redes neurais: princípios e prática. Bookman, Porto Alegre.
- Jardim, J., Neto, C., Dos Santos, M.G., 2006. Brazilian System Operator Online Security Assessment System, in: 2006 IEEE PES Power Systems Conference and Exposition. Presented at the 2006 IEEE PES Power Systems Conference and Exposition, IEEE, Atlanta, Georgia, USA, pp. 7–12. <https://doi.org/10.1109/PSCE.2006.296219>
- Kim, J.-H., 2009. Estimating Classification Error Rate: Repeated Cross-Validation, Repeated Hold-Out and Bootstrap. Computational Statistics & Data Analysis

- 53, 3735–3745.
<https://doi.org/10.1016/j.csda.2009.04.009>
- Li, X., Li, Z., Guan, L., Zhu, L., Liu, F., 2020. Review on Transient Voltage Stability of Power System, in: 2020 IEEE Sustainable Power and Energy Conference (ISPEC). Presented at the 2020 IEEE Sustainable Power and Energy Conference (iSPEC), IEEE, Chengdu, China, pp. 940–947.
<https://doi.org/10.1109/iSPEC50848.2020.9351059>
- Lotufo, A.D.P., Lopes, M.L.M., Minussi, C.R., 2007. Sensitivity analysis by neural networks applied to power systems transient stability. *Electric Power Systems Research* 77, 730–738.
<https://doi.org/10.1016/j.eprsr.2005.09.020>
- Martins, R.P., 2018. *Previsão Probabilística de Energia Solar Utilizando Redes Neurais Com Inferências Bayesianas E Misturas Gaussianas (Dissertação)*. Universidade Federal Fluminense, Niterói.
- Martins, R.P., Ferreira, V.H., Lopes, T.T. e, 2018. Artificial neural network for probabilistic forecasting of the output power of photovoltaic systems, in: 2018 Simposio Brasileiro de Sistemas Elétricos (SBSE). Presented at the 2018 Simposio Brasileiro de Sistemas Elétricos (SBSE) [VII Brazilian Electrical Systems Symposium (SBSE)], IEEE, Niterói, pp. 1–6. <https://doi.org/10.1109/SBSE.2018.8395884>
- Neto, C.A., Quadros, M.A., Passaro, M.C., Pires, G., Ticom, S.D., Farias, R.V.D., Leites, R.A., Penna, L.D., 2011. Utilização da Ferramenta Organon nos Processos do ONS 9.
- Nohara, A.A., Assis, T.M.L., Valentini, T.M., 2009. Avaliação da Estabilidade Transitória de Sistemas de Energia Elétrica através de um Sistema Neuro-Fuzzy 12.
- ONS, 2020. *Conceitos e entendimento da Região de Segurança para uso em Tempo Real*.
- ONS - Operador Nacional do Sistema Elétrico [WWW Document], 2021. . O que é ONS. URL <http://ons.org.br:80/paginas/sobre-o-ons/o-que-e-ons> (accessed 7.19.21).
- Popović, D.P., 1989. An efficient unified methodology for steady-state and dynamic security assessment of power systems. *Electric Power Systems Research* 17, 179–188. [https://doi.org/10.1016/0378-7796\(89\)90020-5](https://doi.org/10.1016/0378-7796(89)90020-5)
- Sadeghkhani, I., Ketabi, A., Feuillet, R., 2009. Estimation of Temporary Overvoltages during Power System Restoration using Artificial Neural Network, in: 2009 15th International Conference on Intelligent System Applications to Power Systems. Presented at the 2009 15th International Conference on Intelligent System Applications to Power Systems (ISAP), IEEE, Curitiba, pp. 1–6.
<https://doi.org/10.1109/ISAP.2009.5352836>
- Sawhney, H., Jeyasurya, B., 2006. A feed-forward artificial neural network with enhanced feature selection for power system transient stability assessment. *Electric Power Systems Research* 76, 1047–1054.
<https://doi.org/10.1016/j.eprsr.2005.12.026>
- Shahidehpour, M., Tinney, F., Yong Fu, 2005. Impact of Security on Power Systems Operation. *Proc. IEEE* 93, 2013–2025.
<https://doi.org/10.1109/JPROC.2005.857490>
- Silva, S.R. e, Schmidt, F., 2016. Reduction of Input Variables in Artificial Neural Networks as from Principal Components Analysis Data in the Modeling of Dissolved Oxygen. *Química Nova*. <https://doi.org/10.5935/0100-4042.20160024>
- Sobbouhi, A.R., Vahedi, A., 2021. Transient stability prediction of power system; a review on methods, classification and considerations. *Electric Power Systems Research* 190, 106853.
<https://doi.org/10.1016/j.eprsr.2020.106853>
- Sterpu, S., Lu, W., Besanger, Y., HadjSaid, N., 2006. Power systems security analysis, in: 2006 IEEE Power Engineering Society General Meeting. Presented at the 2006 IEEE Power Engineering Society General Meeting, IEEE, Montreal, Que., Canada, p. 5 pp.
<https://doi.org/10.1109/PES.2006.1708929>
- Tan, H.M., Zivanovic, R., 2007. Transient stability sensitivity analysis of a simplified power system, in: 2007 Australasian Universities Power Engineering Conference. Presented at the 2007 Australasian Universities Power Engineering Conference (AUPEC), IEEE, Perth, Australia, pp. 1–7.
<https://doi.org/10.1109/AUPEC.2007.4548058>
- Varshney, S., Srivastava, L., Pandit, M., 2012. ANN based integrated security assessment of power system using parallel computing. *International Journal of Electrical Power & Energy Systems* 42, 49–59.
<https://doi.org/10.1016/j.ijepes.2012.03.016>
- Veerasamy, V., Abdul Wahab, N.I., Ramachandran, R., Othman, M.L., Hizam, H., Devendran, V.S., Irudayaraj, A.X.R., Vinayagam, A., 2021. Recurrent network based power flow solution for voltage stability assessment and improvement with distributed energy sources. *Applied Energy* 302, 117524.
<https://doi.org/10.1016/j.apenergy.2021.117524>
- Wang, Y., Wen, F.S., Yang, S.F., 2014. A power system transient stability analysis based on MATLAB, in: 2014 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC). Presented at the 2014 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), IEEE, Hong Kong, pp. 1–4.
<https://doi.org/10.1109/APPEEC.2014.7066021>
- Zhang, G., Eddy Patuwo, B., Y. Hu, M., 1998. Forecasting with artificial neural networks: *International Journal of Forecasting* 14, 35–62.
[https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)