

Predição da Estabilidade Transitória em Sistemas Elétricos de Potência: Uma Avaliação do Conjunto Mínimo de Ciclos de Medição

Gabriel Mancini* Guilherme L. da Cunha*
Ricardo A. Souza Fernandes* Tatiane C. da Costa Fernandes*

* Departamento de Engenharia Elétrica, Universidade Federal de São Carlos, SP, (e-mails: mancini.bdc@gmail.com, guilhermeldacunha@gmail.com, ricardo.asf@ufscar.br, tatianefernandes@ufscar.br).

Abstract: In an electric power system, the assessment and prediction of dynamic security are essential to avoid interruptions in the supply of electricity to consumers, in addition to ensuring that the system operates reliably. Regarding the transient safety assessment, predicting the behavior of the electrical power system in the post-fault period within a short time interval is essential so that preventive and, if necessary, corrective actions are taken. In view of this, the present work proposes to develop an approach based on artificial neural networks, multilayer perceptron, for the prediction of transient stability in an electrical power system through measurements that can be easily acquired by phasor measurement units, such as magnitude and voltage angle of the buses. In the proposed structure, the smallest number of measurement cycles necessary to accurately assess the state of the grid was investigated. The results obtained in the IEEE 68 bus system show the efficiency of the predictor that obtains an accuracy of 97.5% in the classification from 6 consecutive measurement cycles of the system response. When only 1 measurement cycle was provided to the predictor, a high accuracy was also achieved (96.1%) by the proposed methodology.

Resumo: Em um sistema de energia elétrica, a avaliação e a previsão da segurança dinâmica são fundamentais para evitar interrupções no fornecimento de energia elétrica aos consumidores, além de garantir que o sistema opere de forma confiável. No que tange a avaliação da segurança transitória, prever o comportamento do sistema elétrico de potência no período pós-falta dentro de um curto intervalo de tempo é fundamental para que ações preventivas e, se necessário, corretivas sejam tomadas. Diante disto, no presente trabalho propõe-se uma abordagem baseada em redes neurais artificiais, perceptron multicamadas, para predição da estabilidade transitória em um sistema elétrico de potência através de medições que podem ser facilmente adquiridas por unidades de medições fasoriais (do inglês, *Phasor Measurement Unit* - PMU), tais como magnitude e o ângulo de tensão das barras. Investigou na estrutura proposta, a menor quantidade de ciclos de medição necessárias para avaliar com precisão o estado da rede. Os resultados obtidos no sistema IEEE 68 barras mostram a eficiência do preditor, o qual obteve uma acurácia de 97,5% na classificação a partir de 6 ciclos consecutivos de medição da resposta do sistema. Quando apenas 1 ciclo de medição foi fornecido ao preditor, uma alta acurácia também é atingida (96,1%) pela metodologia proposta.

Keywords: Transient Stability Forecast; Artificial Neural Networks; Synchrophasors; Minimum set of measurement cycles.

Palavras-chaves: Previsão da Estabilidade Transitória; Redes Neurais Artificiais; Sincrofasores; Conjunto mínimo de ciclos de medição.

1. INTRODUÇÃO

Com o contínuo aumento da demanda de energia elétrica e da participação de fontes de energia renováveis na matriz energética em diferentes níveis de tensão, a operação dos

* O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e da Fundação de Amparo a Pesquisa do Estado de São Paulo (FAPESP) sob os processos #2020/06333-5 e #2019/08106-9.

sistemas interconectados tem se tornado cada vez mais complexa. Além disso, a tendência pela diversificação nos padrões de consumo nos sistemas de distribuição, motivada pela expansão dos conceitos de *smart grids*, tem levado ao surgimento de novos desafios na área de planejamento e controle de sistemas interconectados (Zhang et al., 2016; Ayar et al., 2017). Neste cenário, a avaliação e a análise da segurança de um sistema de energia elétrica são essenciais para garantir o fornecimento de energia elétrica e a viabilidade da operação.

No planejamento da operação de uma rede elétrica, diversos estudos são desenvolvidos pelos centros de operação para garantir que o sistema opere com uma margem de segurança para condições distintas de carregamento e de topologia. No entanto, conforme pontuado por Morison et al. (2004), não é possível prever todas as eventuais falhas que um sistema está sujeito e suas possíveis condições de operação. Nesse sentido, estudos para predição de potenciais instabilidades da rede a partir de dados coletados no monitoramento da operação do sistema elétrico de potência (SEP) têm se intensificado (Yu et al., 2018; Mihailescu et al., 2017). Diante dessas informações, o operador poderá antever riscos e tomar ações de controle, garantindo o fornecimento ininterrupto de energia elétrica ao consumidor final.

Tradicionalmente, a estabilidade transitória é avaliada a partir da solução por integração numérica de um conjunto de equações diferenciais não lineares, responsáveis por representar as principais dinâmicas do sistema (Vittal, 1992). Usualmente, esta análise envolve a simulação no domínio do tempo da resposta do modelo para diferentes cenários de contingência, demandando tempo e um alto esforço computacional (Kundur et al., 2004).

Ademais, conforme pontuado por Ariff et al. (2015), o modelo de um sistema de potência (base de análise da estabilidade transitória) está sujeito a diferentes tipos de incertezas, as quais podem restringir a capacidade do modelo em representar de forma adequada o comportamento da rede. Nesse sentido, uma abordagem baseada em modelos matemáticos para uma operação em tempo real exige a atualização de parâmetros em um curto intervalo de tempo, o que não é uma tarefa trivial e, pode também, envolver um grande custo computacional.

Recentemente, com o aperfeiçoamento dos sistemas de medição fasorial sincronizados, e com a formação de grandes áreas de monitoramento e controle (do inglês, *Wide-Area Monitoring and Control* - WAMC), é possível realizar medidas de fasores de tensão e corrente ao longo do sistema de energia elétrica de forma sincronizada e com uma alta taxa de amostragem, quando comparado com o tradicional sistema de supervisão e aquisição de dados (do inglês, *Supervisory Control and Data Acquisition* - SCADA). As informações amostradas pelas unidades de medição fasorial (do inglês, *Phasor Measurement Unit* - PMU) em pontos distintos dos sistemas de energia, têm contribuído para que diversas técnicas de processamento de sinais e de aprendizado de máquinas sejam utilizadas para, previsão e análise da operação em uma rede elétrica (Hashiesh et al., 2012; Aminifar et al., 2014).

No que tange a avaliação da estabilidade transitória, técnicas de mineração de dados e aprendizagem de máquina têm sido empregadas para avaliar o comportamento dos geradores síncronos conectados no sistema de potência durante os primeiros segundos de resposta da rede após a ocorrência de uma grande perturbação, analisando a variação angular dos rotores existentes (Hashiesh et al., 2012; Zhang et al., 2016; Tan et al., 2017).

Em Tan et al. (2017), a estabilidade transitória é predita a partir de uma rede neural convolucional (do inglês, *Convolutional Neural Networks* - CNN), cujos dados de entrada são o ângulo e a velocidade angular dos geradores

do sistema em estudo. Nos testes realizados, o índice de acurácia de 97% é atingido pelo classificador. No trabalho realizado por Rahmatian et al. (2017), a classificação da estabilidade é realizada por um modelo baseado em árvores de decisão. A magnitude e o ângulo da tensão das barras de geração, bem como o desvio angular dos rotores dos geradores síncronos em uma janela contendo 5 ciclos de medição de cada variável são utilizados pelo classificador, o qual obtém uma acurácia de 98%. Apesar da alta precisão obtida por ambos trabalhos mencionados, às duas estruturas desenvolvidas utilizam dados de difícil medição por PMUs (ângulo e velocidade angular), o que pode restringir a suas respectivas aplicações em tempo real.

Além da acurácia e da disponibilidade das amostras necessárias para a classificação, outro ponto importante na previsão da estabilidade é que esta deve ocorrer dentro da menor janela de tempo possível, disponibilizando um maior tempo hábil para tomada de decisão pelo operador, caso haja detecção de instabilidade (Soni et al., 2018). No entanto, poucos trabalhos na área são capazes de fornecer uma classificação com alta acurácia a partir de um conjunto reduzido de preditores de sinais medidos diretamente por PMUs, tais como a magnitude e o ângulo de tensão das barras.

Com o intuito de contribuir com essa questão em aberto na literatura, esse trabalho tem como proposta desenvolver um modelo de predição baseado em redes neurais artificiais (RNAs) que identifique o *status* de estabilidade da rede a partir de dados facilmente medidos por PMUs, os sincrofasores da magnitude e ângulo da tensão amostrados nas barras de geração. Além disso, também investiga-se o conjunto mínimo de medidas necessárias para que as redes neurais sejam capazes de prever o comportamento dinâmico da rede após uma perturbação, avaliando a redução da dimensão do vetor de entrada do modelo de predição através da quantidade de ciclos de medição necessárias.

O artigo está estruturado da seguinte forma. Na Seção 2, uma análise crítica em torno dos trabalhos desenvolvidos na área é apresentada, evidenciando as contribuições dessa proposta, enquanto a Seção 3 exibe a configuração do sistema teste utilizado no caso base. A Seção 4 descreve a abordagem proposta e os passos realizados para elaboração do trabalho. A Seção 5 apresenta a acurácia obtida nos testes realizados sobre o sistema IEEE 68 barras. Por fim, as conclusões desse trabalho são detalhadas na Seção 6.

2. ANÁLISE CRÍTICA DA LITERATURA CORRELATA

Ao longo dos últimos anos, o aprimoramento e desenvolvimento das WAMCs, tem tornado possível o uso de dados monitorados para prever e mitigar problemas relacionados a estabilidade e a operação segura de um SEP. Neste contexto, soluções baseadas em técnicas de aprendizado de máquina tais como árvores de decisão, RNAs e máquinas de vetores de suporte (do inglês, *Support Vector Machine* - SVM) têm sido amplamente utilizadas para mapear ou prever o comportamento da rede a partir dados amostrados (Gurusinghe and Rajapakse, 2016; Yu et al., 2018; da Cunha et al., 2022). As técnicas de aprendizado de máquina utilizam um conjunto de dados de pré-definidos

de forma *offline* para extrair a relação entre os parâmetros do sistema e as condições de estabilidade correspondentes. Uma vez que esta relação seja estabelecida, a nova situação de estabilidade transitória pode ser avaliada com mínimo esforço computacional, tornando assim possível a avaliação *online*.

Em Gomez et al. (2011), os autores desenvolveram uma estrutura centralizada alimentada por dados medidos nas barras de geração para prever a estabilidade transitória da rede, em que um classificador baseado em SVM é construído. Para os diferentes cenários avaliados (condições de carga e tipos de perturbações), os resultados obtidos no sistema IEEE 39 barras evidenciam a acurácia da abordagem, o qual atinge 98% de acurácia quando o preditor tem como vetor de entrada os 4 primeiros ciclos de medição da magnitude da tensão nas barras de geração no período pós-falta.

Árvores de decisão e uma variação da técnica SVM para múltiplas classes (do inglês, *Multiclass Support Vector Machine* - MSVM) são aplicadas por Guo and Milanovi (2016) para definir o estado de estabilidade da rede. A classificação da estabilidade é realizada a partir da medida do ângulo do rotor dos geradores conectados no sistema em estudo, o sistema IEEE 68 barras. Os autores avaliam a acurácia da técnica mediante a quantidade de ciclos utilizados para que o classificador realize a predição, no qual uma acurácia superior a 98% é atingida para um vetor de entrada composto por no mínimo 10 ciclos de medição.

Dentre os classificadores, métodos baseados em redes RNAs também têm demonstrado grande precisão na classificação da estabilidade, atingido um índice de acurácia de aproximadamente 98% (Hashiesh et al., 2012; Siddiqui et al., 2018; Shi et al., 2020).

Hashiesh et al. (2012), propõem uma estrutura responsável por identificar os cenários de instabilidade em uma *smart grid* a partir de classificador composto por uma RNA com 2 camadas, bem como um esquema de ação corretiva para mitigar os problemas relacionados com a instabilidade. Testes são realizados no sistema IEEE 39 barras, nos quais a RNA alimentada com a magnitude e o ângulo de tensão das barras de geração alcança um patamar de 98% de acurácia. Em Siddiqui et al. (2018), os seis primeiros ciclos consecutivos da magnitude da tensão e ângulo do rotor mensurados nas barras de geração são os atributos de entrada de uma rede neural radial (do inglês, *Radial Basis Function* - RBF). A partir da estrutura proposta, os autores identificam a estabilidade transitória do sistema em estudo, bem como o grupos de geradores do sistema que oscilam de forma coerente. A eficácia da abordagem proposta também é avaliada no sistema IEEE 39 barras, no qual uma taxa de erro de aproximadamente 5% é obtida na estimação do valor do ângulo do rotor.

Recentemente, RNAs de aprendizagem profunda também têm sido aplicadas para analisar a estabilidade transitória da rede (Shi et al., 2020; Stiasny et al., 2021). Em Shi et al. (2020) permite classificar a operação do sistema no período pós-falta em três categorias distintas: estável, instável aperiódico e instável oscilatório. A partir de uma janela de 0,25 segundos (aproximadamente de 15 ciclos de medição) do fasor de tensão das barras de geração do

sistema teste, a abordagem realiza essa classificação. Nos testes realizados no sistema IEEE 39 barras uma acurácia de 96,5% foi atingida pelo método, enquanto no sistema de 179 barras, um índice superior de acurácia (98,1%) foi obtido. No entanto, nota-se que apesar de ter sido aplicada uma arquitetura mais complexa, uma acurácia similar aos demais trabalhos foi encontrada.

Apesar das grandes evoluções na área, uma discussão mais aprofundada sobre a quantidade mínima de preditores necessários, ou seja, número de ciclos de medição para que a classificação da estabilidade transitória seja realizada ainda permanece em aberto na literatura. Nesse sentido, o trabalho desenvolvido por Yu et al. (2018) é pioneiro na área. Os autores propõem uma rede neural recorrente, a memória de longa curta duração (do inglês, *long short-term memory* - LSTM) para avaliar a estabilidade transitória. Ademais, utilizam uma flexibilização do índice de avaliação da estabilidade transitória (do inglês, *Transient Stability Index* - TSI) para realizar a classificação, o qual leva em consideração a máxima diferença angular entre quaisquer dois geradores do SEP. Caso o valor do TSI seja abaixo de um determinado limiar, o estado do sistema é definido como indeterminado. Tal alteração permite que a RNA recorrente seja capaz de classificar o estado de estabilidade do sistema em estável, instável e indeterminado apenas com um ciclo de medição. Os resultados obtidos apresentaram 99% de acurácia para o sistema 39 barras IEEE (considerando apenas a classificação entre casos estáveis e instáveis), quando 8 ciclos dos fasores de tensão de todas as barras do sistema em estudo são considerados como preditores.

Os principais trabalhos avaliados para classificar a estabilidade transitória, para aplicações em tempo real, são apresentados de forma sumarizada na Tabela 1, na qual as variáveis V e θ correspondem à magnitude e ângulo da tensão na barra, enquanto δ refere-se ao ângulo do rotor de um dado gerador. Nota-se que a acurácia atingida nos trabalhos elencados é alta, atingindo um patamar de 98%, e que o sistema IEEE 39 barras é amplamente utilizado para verificar a eficiência da abordagem. Com relação à quantidade mínima de ciclos consecutivos de medição necessários, observa-se que uma alta precisão é alcançada quando apenas 4 ciclos foram utilizados. Apesar do Yu et al. (2018) realizar classificações com apenas 1 ciclo de medição, é importante ressaltar que ele poderá classificar uma parcela das amostras como indeterminado, não informando o operador sobre o real estado da rede. Portanto, foi informado na Tabela 1 o resultado em que os autores classificam as amostras em apenas duas classes: estável e instável.

Tabela 1. Comparação entre as abordagens.

Referências	Algoritmos	Atributo	Ciclos	Acurácia	Barras
Gomez et al. (2011)	SVM	V	4	98,0%	39
Hashiesh et al. (2012)	RNA	$V \angle \theta$	8	98,0%	39
Guo and Milanovi (2016)	DT	δ	10	98,0%	68
Yu et al. (2018)	LSTM	V	8	99,0%	39
Shi et al. (2020)	CNN	V	15	98,1%	179

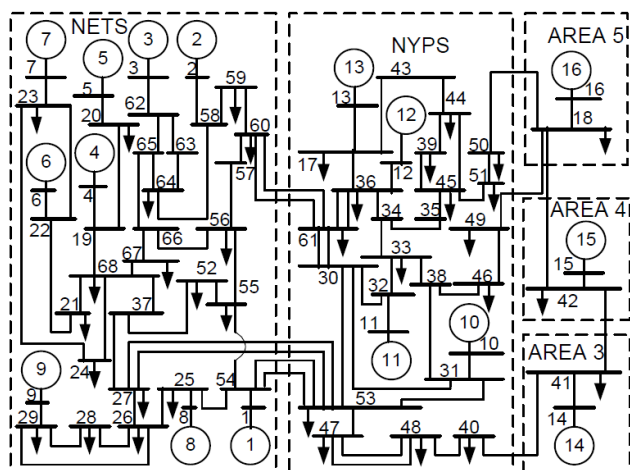
3. SISTEMA TESTE

Para testar a eficácia da abordagem, as simulações foram realizadas no sistema IEEE 68 barras, exibido na Figura 1,

o equivalente de ordem reduzida dos sistemas *New England Test System* (NETS) e do sistema *New York Power System* (NYPS). Este sistema teste é composto por 5 áreas, em que a área 1 representa o equivalente reduzido do NETS e a área 2 refere-se ao *New York* (NYPS). As demais regiões 3, 4 e 5 são equivalentes de área. O sistema é composto por 16 barras de geração e, no caso base, a potência ativa total consumida pelas cargas é de 17.621 MW.

Com relação ao modelo dinâmico, todos os geradores são representados por modelos de sexta ordem (Kundur, 1994). Os geradores conectados nas barras 1 a 12 (G1 a G12) foram equipados com estabilizadores de tensão e reguladores automáticos de tensão, cujos modelos e parâmetros são detalhados em Canizares et al. (2017). Os geradores 14 e 16 também foram equipados com regulador de tensão. Todos os limites de geração de potência ativa e reativa dos geradores e reguladores de tensão foram respeitados.

Figura 1. Diagrama unifilar do sistema IEEE 68 Barras.



Fonte: Canizares et al. (2017).

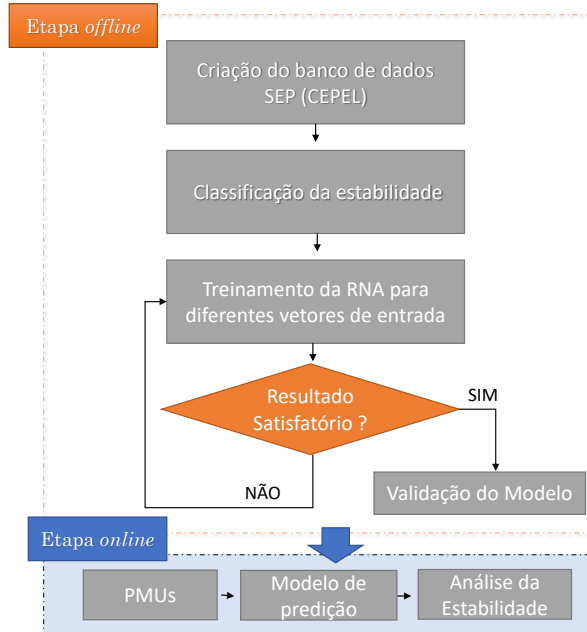
4. ABORDAGEM PROPOSTA

Com o objetivo de desenvolver uma estrutura que possibilite ao operador avaliar em um curto intervalo de tempo a estabilidade transitória do SEP a partir de medições disponíveis em um sistema real, tais como as fornecidas pelas PMUs, neste trabalho investiga-se a utilização de RNAs para identificar o comportamento transitório de uma rede no período pós-falta, de modo a prever situações de instabilidade.

Para isso, uma abordagem centralizada é proposta, na qual as medidas realizadas apenas nas barras de geração do sistema em estudo são necessárias. O classificador proposto deve ser capaz de identificar se a resposta do sistema pós-perturbação é estável ou instável, a partir dos primeiros ciclos de medição da resposta do sistema no período pós-falta. Para identificar o conjunto mínimo de medidas necessárias, desenvolve-se um modelo preditivo para cada vetor de entrada e a partir de uma abordagem estatística identifica-se a média da acurácia obtida em cada arquitetura avaliada. Desta forma, é possível avaliar a relação entre a acurácia e a menor quantidade de medidas necessárias para a classificação.

Uma visão geral das principais etapas que compõe a abordagem proposto é exibida na Figura 2. Após o modelo de predição ser estabelecido, a técnica deve ser capaz de prever cenários de instabilidade transitória a partir do novo conjunto de dados medidos. A descrição detalhada de cada etapa é descrita em sequência.

Figura 2. Diagrama da abordagem utilizada.



Fonte: Autoria própria.

4.1 Preparação do Banco de Dados

A primeira etapa da abordagem consiste em preparar um conjunto de dados que contenha a relação do comportamento transitório da rede para diferentes cenários de operação e perturbações. Para gerar essas condições de operação a partir do caso base, simulações são realizadas no sistema teste por meio dos programas ANAREDE e ANATEM do Centro de Pesquisa em Engenharia Elétrica (CEPEL), os quais são amplamente utilizados no setor energético brasileiro.

Além do caso base, dois novos níveis de carregamento são estabelecidos para o sistema teste, a saber: leve (17% menor em relação a carga nominal) e pesada (17% maior em relação a carga nominal). O método do fluxo de carga continuado foi aplicado para identificar o nível máximo de carregamento desse sistema teste, conforme realizado em da Cunha et al. (2022).

Para cada nível de carregamento da rede são aplicadas faltas trifásicas sobre o sistema teste, em que os seguintes parâmetros são alterados:

- (1) **Linha de transmissão** - são aplicadas faltas trifásicas em cada uma das 29 linhas disponíveis do sistema IEEE 68 barras. Exclui-se as linhas que provocam o ilhamento dos geradores;
- (2) **Tempo de duração da falta** - são testados de forma determinística os seguintes valores de tempo de duração da falta, 350, 400, 450, 500, 550, 600 e 650 ms;

- (3) **Posição na linha de transmissão** - são definidas de forma aleatória a posição da linha em que a falta trifásica é aplicada no intervalo entre 20% a 80% do comprimento da linha.

As simulações, de acordo com os itens 1, 2 e 3, são realizadas na seguinte ordem. Para cada linha de transmissão avaliada, aplica-se faltas trifásicas para cada um dos valores determinísticos de tempo de duração de falta, sorteando-se de forma aleatória a posição da falta. Esse procedimento é repetido para os três níveis de carregamento do sistema teste.

A resposta transitória da rede para cada falta trifásica aplicada é amostrada no *software* ANATEM, com uma taxa de 0,01667 segundos (valor compatível com a de uma PMU). Uma janela com duração de 20 s dos sinais de magnitude e ângulo da tensão, bem como do desvio angular das barras de geração são registradas.

4.2 Classificação da Estabilidade Transitória

Para classificar a estabilidade transitória a partir dos sinais medidos, utiliza-se o índice de Estabilidade Transitória, o TSI. Este índice se fundamenta na separação máxima do ângulo do rotor entre quaisquer dois geradores do sistema após a eliminação da perturbação. O mesmo é calculado pela equação (1):

$$TSI = \frac{360 - \delta_{max}}{360 + \delta_{max}} \quad (1)$$

em que a diferença angular entre os geradores é representada pelo δ_{max} . Quando $TSI > 0$, o sistema é estável, caso contrário, o sistema é instável.

Apesar da equação (1) não restringir o instante de tempo em que o índice pode ser aplicado, o intervalo de tempo avaliado após a remoção da falta é importante para determinação da variável δ_{max} e, conseqüentemente, do índice TSI. Assim como já aplicado na literatura correlata (Yu et al., 2018), neste trabalho será utilizada a 8ª amostra consecutiva (8º ciclo de medição) após a eliminação da falta para categorizar o comportamento do sistema.

4.3 Redes Neurais Artificiais

A partir do conjunto de dados gerado, inicia-se a etapa de treinamento e validação da RNA. Deste modo, 70% do conjunto de dados é utilizado para o treinamento, enquanto a parcela restante de 30% é utilizada para validação. Nos conjuntos resultantes de treinamento e validação, prepara-se um conjunto balanceado, com quantidades semelhantes de casos instáveis e casos estáveis, reduzindo a probabilidade de *overfitting* do classificador.

Além da separação e balanceamento do conjunto de dados, é necessário determinar a arquitetura da RNA na construção do modelo de predição. Essa arquitetura é definida de acordo com a dimensão do vetor de entrada.

Supondo um sistema testes com n barras de geração, o vetor das variáveis de entrada para o treinamento da rede é organizado da seguinte forma:

$$x = [V_{B_1, T_1} \ V_{B_1, T_2} \ \dots \ V_{B_1, T_m} \ \dots \ V_{B_n, T_1} \ \dots \ V_{B_n, T_m}]$$

em que V_{B_i} corresponde ao valor da magnitude e do ângulo da tensão de cada i -ésima barra de geração, ou seja, $V = V_{B_i} \angle \theta_{B_i}$. A variável T refere-se ao instante de medição da variável no período pós-falta, indicando a quantidade de amostras medidas após a remoção da perturbação, em um total de m ciclos.

Portanto, o vetor utilizado para o treinamento da RNA depende da quantidade de ciclos medidos no pós-falta. Quando um menor número de ciclos é necessário, isso reduz a dimensão do vetor de características para a entrada da RNA, simplificando a arquitetura da RNA. Dessa forma, é possível reduzir o tempo de processamento necessário no treinamento e nas predições. Por fim, com a redução da dimensão do vetor de entrada, a quantidade de instâncias necessárias para compor o conjunto de dados é menor, tornando o modelo menos propenso ao *overfitting* (Geron, 2017).

Para cada vetor de entrada avaliado, uma arquitetura da RNA foi definida. Diferentes combinações de quantidade de neurônios considerando até duas camadas escondidas para cada RNA foram testadas. Iniciando com uma camada escondida, a quantidade de neurônios é incrementada, com discretização de 5 neurônios, até atingir o máximo de 50 neurônios por camada. Para cada quantidade de neurônios avaliado na primeira camada, o mesmo procedimento é utilizado para testar a quantidade de neurônios necessários na segunda camada escondida. O *software* escolhido para implementação das RNAs é o Matlab, o algoritmo utilizado no treinamento é o *Levenberg-Marquardt* e a camada de saída utiliza uma função de ativação linear. O critério de parada para o treinamento da RNA é o erro quadrático médio (MSE).

Um total de 10 treinamentos foram realizados para cada arquitetura avaliada. Uma vez encontrada a arquitetura ideal, ou seja, a arquitetura que resulte em uma maior acurácia média, essa foi escolhida para realizar a predição de acordo com o número de ciclos de medição avaliado.

Após escolher a arquitetura ideal para a predição deste trabalho, foi realizado o treinamento de 50 RNAs com tal arquitetura, a fim de utilizar como resultado a média dentre todas elas. Esse procedimento garantiu maior eficácia dos resultados obtidos, uma vez que na etapa de treinamento de uma RNA os pesos adquiridos pelas variáveis de entrada nem sempre se repetem. Este procedimento foi repetido para todas as RNAs de acordo com a quantidade de ciclos utilizados para a predição.

Já os dados de saída da RNA foram fornecidos na segunda etapa são categorizados na etapa de Classificação da Estabilidade Transitória (subseção 4.2). Eles foram definidos pelo índice TSI e possuem valores de 0 ou 1, que representam a estabilidade do sistema. Assim, o vetor de saída consiste em apenas uma variável para cada instância do conjunto de dados.

4.4 Métricas de Análise de Desempenho

Com o objetivo de analisar o desempenho do classificador, a métrica adotada na execução deste trabalho foi a

acurácia, a qual permitiu identificar a proximidade entre o valor obtido experimentalmente e o valor verdadeiro na medição. Esse índice foi calculado por meio da seguinte expressão:

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + VN + FN} \quad (2)$$

em que *VP* refere-se aos verdadeiros positivos, ou seja, são os cenários que foram preditos como estáveis e são realmente estáveis. *FN* correspondem aos falsos negativos, isto é, os casos es estáveis que foram preditos como instáveis. *FP* são os falsos positivos, valores que foram preditos como estáveis mas na verdade são instáveis, e por último, *VN* são os verdadeiros negativos, valores preditos como instáveis e que são realmente instáveis.

5. TESTES APLICADOS E RESULTADOS

Para avaliar a eficácia da abordagem proposta, testes foram realizados no sistema IEEE 68 barras. Inicialmente, a arquitetura da RNA necessária para classificação da estabilidade de acordo com o número de característica do vetor de entrada foi estabelecida. A partir dessa definição da estrutura da RNA para predição, avaliou-se o conjunto mínimo de medições consecutivas necessárias por meio de uma análise estatística, com o objetivo de identificar o impacto da redução da dimensão do vetor de entrada na acurácia da predição.

5.1 Conjunto de dados do sistema IEEE 68 barras

Com a aplicação do procedimento proposto sobre o sistema teste, o conjunto de dados formado foi balanceado para os 4186 casos simulados. Portanto, deste total de amostras, 2093 referem-se a cenários em que o sistema é estável enquanto em que nos 2093 casos restantes o sistema apresenta um comportamento dinâmico instável.

O balanceamento dos cenários estáveis e instáveis foi realizado com o tempo de duração da falta conforme exibido na Figura 3. Note que as faltas trifásicas com duração de 350 ms e 400 ms resultam em um menor número de cenários instáveis e portanto, um menor número de instâncias foi gerada para faltas trifásicas com essas características.

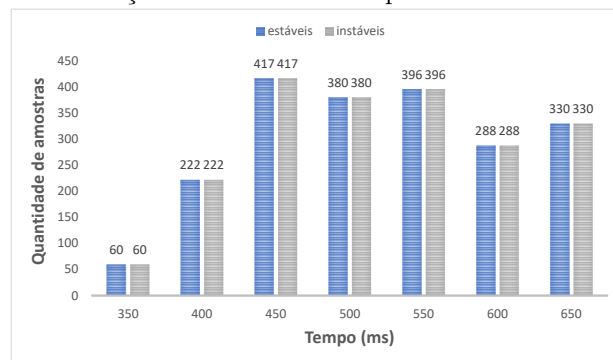
O conjunto de dados foi dividido respeitando-se o balanceamento entre os cenários, resultando em 2928 (70%) amostras para treinamento e 1258 (30%) para teste.

5.2 Resultado da classificação da estabilidade transitória de acordo com o conjunto de ciclos de medição

A camada de entrada de cada modelo de predição treinado altera de acordo com a dimensão do vetor de entrada, ou seja, mediante ao número ciclos de medição consecutivos da magnitude e ângulo de tensão de cada barra de geração selecionados como atributos. Considerando um total de 16 barras de geração no sistema teste, a Tabela 2 exhibe a quantidade de atributos que formam o vetor de entrada para cada RNA avaliada.

Com o objetivo de encontrar a melhor arquitetura para as RNAs, 64 redes foram testadas para cada ciclo, variando

Figura 3. Relação dos casos estáveis e instáveis por tempo de duração da falta trifásica aplicada.



Fonte: Autoria própria.

Tabela 2. Dimensão da camada de entrada da RNA de acordo com o número de ciclos de medição consecutivos necessários.

Qtd de Ciclos	Dimensão do Vetor de entrada da RNA
8 Ciclos	256
7 Ciclos	224
6 Ciclos	192
5 Ciclos	160
4 Ciclos	128
3 Ciclos	96
2 Ciclos	64
1 Ciclo	32

suas camadas de 5 em 5 neurônios. Primeiro foi utilizado apenas 1 camada variando os seus neurônios de 5 a 50. Posteriormente, adicionou-se uma segunda camada para cada uma das redes anteriores. Está segunda camada parte da quantidade de nerônios da primeira camada e aumenta até atingir um máximo de 50 neurônios.

Como no processo de treinamento de uma RNA os pesos sinápticos podem sofrer pequenas variações, foram realizados 10 treinamentos por arquitetura a fim extrair uma média dos resultados, reduzindo o impacto da aleatoriedade dos valores dos pesos sinápticos na acurácia obtida pelo preditor avaliado. Dentre as 64 redes treinadas para cada grupos de ciclo, a Tabela 3 apresenta a quantidade de neurônios presentes em cada camada escondida da arquitetura que atingiu o maior valor médio de acurácia. Note que independente da quantidade de ciclos no vetor de entrada, 20 ou 25 neurônios na 1ª camada já são suficientes para classificação nas arquiteturas avaliadas.

A Tabela 3 também mostra que os 8 modelos de predição construídos alcançam uma alta acurácia média, acima de 96,0 %. A maior acurácia média (97,85 %), foi obtida por duas RNAs, de 5 e 6 ciclos de medição, enquanto a rede de 2 ciclos atinge o menor índice de acurácia médio (96,47 %), resultando em um desvio de apenas 1,33%.

5.3 Análise Estatística da Classificação da Estabilidade Transitória

Para uma análise mais aprofundada sobre o comportamento das RNAs com relação à quantidade de ciclos de medição, uma análise estatística foi também desenvolvida.

Tabela 3. Quantidade de neurônios por camada.

Redes	1º Camada	2º Camada	Acurácia Média
8 Ciclos	20	25	97,60%
7 Ciclos	25	45	97,80%
6 Ciclos	25	35	97,85%
5 Ciclos	25	50	97,85%
4 Ciclos	20	20	97,74%
3 Ciclos	20	40	96,91%
2 Ciclos	20	30	96,47%
1 Ciclo	20	20	96,62%

Com esse objetivo, 50 RNAs foram treinadas para cada configuração exibida na Tabela 3. A acurácia média e o desvio padrão de cada rede é exibido na Tabela 4.

Tabela 4. Acurácias e desvio padrão absoluto dos 50 treinamentos realizados para cada modelo de predição.

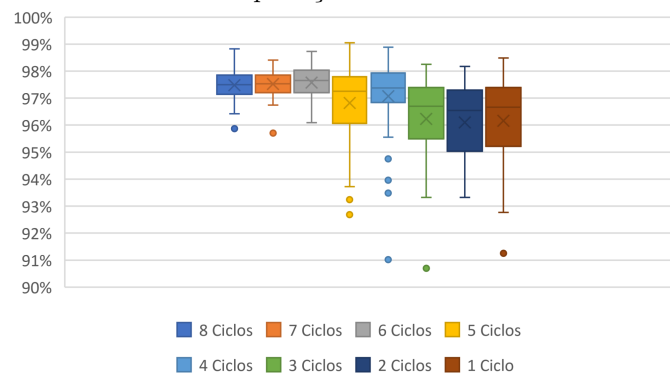
Rede	Acurácia Média	Desvio Padrão	Acurácia Máxima
8 Ciclos	97,48%	0,58	98,82%
7 Ciclos	97,53%	0,50	98,41%
6 Ciclos	97,58%	0,62	98,73%
5 Ciclos	97,04%	1,23	99,05%
4 Ciclos	97,02%	1,44	98,89%
3 Ciclos	96,23%	1,81	98,25%
2 Ciclos	96,10%	1,58	98,17%
1 Ciclos	96,16%	1,68	98,47%

Note pela Tabela 4, que acurácia média obtida pelas RNAs ultrapassam 96%, consolidando o patamar exibido anteriormente. A acurácia média mais elevada (97,58%) foi obtida pelas RNAs de 7 e 6 ciclos, resultando em uma discrepância de apenas 1,4% entre o valor máximo e mínimo de acurácia média. A acurácia máxima mais elevada (99,05%) foi obtida pela rede de 5 ciclos, e a acurácia máxima das demais RNAs ultrapassaram 98%. O desvio padrão apresentado na Tabela 4, demonstra maior uniformidade dos dados para as RNAs de 8, 7 e 6 ciclos, enquanto que para uma menor quantidade de ciclos a uniformidade dos dados diminui.

A distribuição dos valores de acurácia obtidos por cada um dos 8 modelos de predição foi investigada a partir do boxplot detalhado na Figura 4. Note que as RNAs de 7 ciclos são as que apresentam uma menor área de distribuição entre os quartis, atingindo valores de acurácia entre 96,74% e 98,41%. O modelo de predição alimentado por 6 ciclos consecutivos apresenta uma alta acurácia média e não apresenta nenhum *outlier*, estabelecendo uma acurácia acima de 96%, independente da RNA treinada.

As RNAs alimentadas por 3, 2 e 1 ciclos consecutivos de medição apresentam uma distribuição semelhante de valores de acurácia, estando limitadas entre os valores 92,77% e 98,49%. Note que um modelo de predição que requer uma menor quantidade de ciclos também é capaz de fornecer informações sobre a estabilidade transitória da rede ao operador, no entanto, há uma pequena redução no patamar da acurácia resultante do modelo. Por outro lado, essa predição é realizada dentro do menor intervalo de tempo possível, resultando em maior tempo hábil para o operador tomar uma ação coordenada de correção.

Figura 4. Boxplot do resultado das 50 RNAs avaliadas para cada modelo de predição.



Fonte: Autoria própria.

5.4 Discussão

A partir de RNAs de baixa complexidade computacional (poucas camadas), a abordagem proposta foi capaz de prever se o comportamento do sistema no período pós-falta será estável ou instável com uma alta acurácia média (acima de 96%), dentro do menor intervalo de tempo possível, ou seja, considerando apenas um ciclo de medição dos fasores de tensão das barras de geração. Se uma maior janela de dados foi considerada no vetor de entrada, aumentando para 6 ciclos de medição, a acurácia média pode alcançar o patamar de 97,5%. Para todas as amostras avaliadas para o modelo de 6 ciclos, independente do grau de severidade da falta, a acurácia atingida foi acima de 96%, evidenciando a eficácia da abordagem proposta.

Note que esse resultado está próximo aos valores exibidos na Tabela 1, cujo patamar alcançado do valor máximo de acurácia é de 98% por Hashiesh et al. (2012), em que uma RNA de duas camadas foi aplicada no sistema 39 barras IEEE. Em termos de acurácia máxima, o valor atingido para uma rede de 1 ciclo de medição foi de 98,47%, superior ao valor obtido por Hashiesh et al. (2012).

Portanto, a partir de uma técnica relativamente simples, uma RNA do tipo perceptron de múltiplas camadas, a abordagem proposto atinge uma acurácia muito próxima a técnicas mais sofisticadas, tal como uma CNN (Shi et al., 2020), para uma quantidade igual ou inferior de ciclos de medição. Essa característica torna a abordagem atrativa para o auxílio a tomada de decisão por parte dos operadores do SEP.

6. CONCLUSÕES

A abordagem proposta neste trabalho foi capaz de realizar a predição da estabilidade transitória com auxílio de RNAs utilizando dados facilmente amostrados por PMUs localizados nas barras de geração, possibilitando a aplicação da abordagem em sistemas reais. Para o treinamento de cada modelo de predição avaliado foi construído um conjunto de dados com alta diversidade de condições de operação, o que contribuiu para generalização de cada RNA desenvolvida de acordo com a dimensão do vetor de entrada.

Os resultados obtidos no sistema IEEE 68 barras demonstraram um bom desempenho dos modelos de predição de-

envolvidos, resultando em uma acurácia média superior a 97,85% quando se utiliza pelos menos 6 ciclos consecutivos de medição de cada variável (magnitude e ângulo da tensão da barra de geração) na composição do vetor de entrada.

A análise estatística do desempenho do classificador para diferentes conjuntos de ciclos de medição explorou o *trade-off* entre a velocidade de disponibilização da predição e a acurácia, sendo um dos diferenciais deste trabalho. Verificou-se que foi possível predizer com apenas 1 ciclo de medição, no entanto, ouve uma pequena redução na acurácia média obtida.

As perspectivas futuras desse trabalho envolvem realizar uma seleção de atributos com o objetivo de averiguar a importância de cada barra de geração de um SEP, bem como das variáveis de magnitude e ângulo da tensão no desempenho das RNAs. Esse processo pode reduzir ainda mais o custo computacional empregado para o treinamento das RNAs, assim como o tempo para a realizar a predição da estabilidade transitória. Uma menor quantidade de dados para a predição também pode resultar em uma menor quantidade de medidores na rede elétrica, reduzindo os custos de instalação e manutenção de equipamentos.

REFERÊNCIAS

- Aminifar, F., Fotuhi-Firuzabad, M., Safdarian, A., Davoudi, A., and Shahidehpour, M. (2014). Synchrophasor measurement technology in power systems: Panorama and state-of-the-art. *IEEE Access*, 2, 1607–1628.
- Ariff, M.A.M., Pal, B.C., and Singh, A.K. (2015). Estimating dynamic model parameters for adaptive protection and control in power system. *IEEE Transactions on Power Systems*, 30(2), 829–839.
- Ayar, M., Obuz, S., Trevizan, R.D., Bretas, A.S., and Latchman, H.A. (2017). A distributed control approach for enhancing smart grid transient stability and resilience. *IEEE Transactions on Smart Grid*, 8(6), 3035–3044.
- Canizares, C., Fernandes, T., Geraldi, E., Gerin-Lajoie, L., Gibbard, M., Chair), I.H.T.P., Kersulis, J., Kuiava, R., Lima, L., DeMarco, F., Martins, N., Pal, B.C., Piardi, A., Chair), R.R.T., dos Santos, J., Silva, D., Singh, A.K., Tamimi, B., and Vowles, D. (2017). Benchmark models for the analysis and control of small-signal oscillatory dynamics in power systems. *IEEE Transactions on Power Systems*, 32(1), 715–722.
- da Cunha, G.L., Fernandes, R.A., and Fernandes, T.C.C. (2022). Small-signal stability analysis in smart grids: An approach based on distributed decision trees. *Electric Power Systems Research*, 203, 107651.
- Geron, A. (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O’reilly., United States.
- Gomez, F.R., Rajapakse, A.D., Annakkage, U.D., and Fernando, I.T. (2011). Support vector machine-based algorithm for post-fault transient stability status prediction using synchronized measurements. *IEEE Transactions on Power Systems*, 26(3), 1474–1483.
- Guo, T. and Milanovi, J.V. (2016). Online identification of power system dynamic signature using pmu measurements and data mining. *IEEE Transactions on Power Systems*, 31(3), 1760–1768.
- Gurusinghe, D.R. and Rajapakse, A.D. (2016). Post-disturbance transient stability status prediction using synchrophasor measurements. *IEEE Transactions on Power Systems*, 31(5), 3656–3664.
- Hashiesh, F., Mostafa, H.E., Khatib, A., Helal, I., and Mansour, M.M. (2012). An intelligent wide area synchrophasor based system for predicting and mitigating transient instabilities. *IEEE Transactions on Smart Grid*, 645–652.
- Kundur, P. (1994). *Power System Stability and Control*. McGraw-Hill, New York, NY.
- Kundur, P., Paserba, J., Ajarapu, V., Andersson, G., Bose, A., Canizares, C., Hatziargyriou, N., Hill, D., Stankovic, A., Taylor, C., Van Cutsem, T., and Vittal, V. (2004). Definition and classification of power system stability ieeecigre joint task force on stability terms and definitions. *IEEE Transactions on Power Systems*, 19(3), 1387–1401.
- Mihailescu, R.C., Ossowski, S., and Klusch, M. (2017). Ecoop: Applying dynamic coalition formation to the power regulation problem in smart grids. *Computational Intelligence*, 33(3), 401–427.
- Morison, K., Lei Wang, and Kundur, P. (2004). Power system security assessment. *IEEE Power and Energy Magazine*, 2(5), 30–39.
- Rahmatian, M., Chen, Y.C., Palizban, A., Moshref, A., and Dunford, W.G. (2017). Transient stability assessment via decision trees and multivariate adaptive regression splines. *Electric Power Systems Research*, 142, 320–328.
- Shi, Z., Yao, W., Zeng, L., Wen, J., Fang, J., Ai, X., and Wen, J. (2020). Convolutional neural network-based power system transient stability assessment and instability mode prediction. *Applied Energy*, 263, 114586.
- Siddiqui, S.A., Verma, K., Niazi, K.R., and Fozdar, M. (2018). Real-time monitoring of post-fault scenario for determining generator coherency and transient stability through ann. *IEEE Transactions on Industry Applications*, 54(1), 685–692.
- Soni, B.P., Saxena, A., Gupta, V., and Surana, S. (2018). Identification of generator criticality and transient instability by supervising real-time rotor angle trajectories employing rbfn. *ISA Transactions*, 83, 66–88.
- Stiasny, J., Misyris, G.S., and Chatzivasileiadis, S. (2021). Transient stability analysis with physics-informed neural networks.
- Tan, B., Yang, J., Pan, X., Li, J., Xie, P., and Zeng, C. (2017). Representational learning approach for power system transient stability assessment based on convolutional neural network. *The Journal of Engineering*, 2017(13), 1847–1850.
- Vittal, A.F.E.V. (1992). Power system transient stability analysis using the transient energy function method. *Englewood Cliffs NJ, USA: Prentice-Hall*.
- Yu, J.J.Q., Hill, D.J., Lam, A.Y.S., Gu, J., and Li, V.O.K. (2018). Intelligent time-adaptive transient stability assessment system. *IEEE Transactions on Power Systems*, 33(1), 1049–1058.
- Zhang, J., Chung, C.Y., Wang, Z., and Zheng, X. (2016). Instantaneous electromechanical dynamics monitoring in smart transmission grid. *IEEE Transactions on Industrial Informatics*, 12(2), 844–852.