

UNIVERSIDADE FEDERAL DE SÃO CARLOS– UFSCAR  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA– CCET  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA– DEE  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA– PPGEE

**Gabriel Mancini**

**Uma Abordagem para Predição da  
Estabilidade Transitória em Sistemas  
Elétricos de Potência a partir de Redes  
Neurais Artificiais**

São Carlos  
2022



**Gabriel Mancini**

**Uma Abordagem para Predição da  
Estabilidade Transitória em Sistemas  
Elétricos de Potência a partir de Redes  
Neurais Artificiais**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas Elétricos e Eletrônicos

Orientador: Tatiane Cristina da Costa Fernandes

Coorientador: Ricardo Augusto Souza Fernandes

São Carlos

2022





**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

Centro de Ciências Exatas e de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

---

**Folha de Aprovação**

---

Defesa de Dissertação de Mestrado do candidato Gabriel Mancini, realizada em 22/09/2022.

**Comissão Julgadora:**

Profa. Dra. Tatiane Cristina da Costa Fernandes (UFSCar)

Prof. Dr. Edson Luis Geraldi Junior (IFSP)

Prof. Dr. Guilherme Guimarães Lage (UFSCar)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Elétrica.



---

# Agradecimentos

---

Nesses anos de mestrado, de muito estudo, esforço e empenho, gostaria de agradecer a algumas pessoas que me acompanharam e foram fundamentais para a realização de mais uma etapa na minha vida. Por isso, expresso aqui, através de palavras sinceras, a importância delas e a minha sincera gratidão. Primeiramente agradeço a Deus e Nossa Senhora da Conceição Aparecida por sempre estarem olhando por mim. Agradeço aos meus pais Luís Fernando Mancini e Valéria Cristina Aguiar Mancini, sem eles nada faria sentido, toda a confiança depositada em minha pessoa por eles é algo que devo agradecer a minha vida toda. Agradeço também meus irmãos Matheus Mancini e Lucas Mancini, por serem de grande importância na minha vida e me incentivarem sempre que necessário. Agradeço imensamente minha avó Irene Franchin Mancini é sem dúvida a mulher da minha vida e me ajudou a ser quem sou hoje, sem ela nada seria possível. Em suma agradeço a toda a minha família pela compreensão, ao serem privados em muitos momentos da minha companhia e atenção, e pelo profundo apoio, me estimulando nos momentos mais difíceis. Obrigado por desejarem sempre o melhor para mim, pelo esforço que fizeram para que eu pudesse superar cada obstáculo em meu caminho e chegar aqui e, principalmente, pelo amor imenso que vocês têm por mim. A vocês, minha família, sou eternamente grato por tudo que sou, por tudo que consegui conquistar e pela felicidade que tenho. Minha imensa gratidão a professora Tatiane Cristina da Costa Fernandes, minha orientadora, a qual me ajudou muito, uma excelente profissional. Obrigado por sua dedicação, por ser muito atenciosa e paciente, e sobre tudo por toda ajuda fornecida mesmo em seus horários de descanso. E, principalmente, obrigado por depositar sua confiança em mim ao longo desses anos. Um grande obrigado ao meu amigo Guilherme Cunha, que me ajudou imensamente durante todo o meu trabalho, sempre atencioso mesmo em seus horários de lazer. Gostaria de agradecer ao professor Ricardo Augusto Souza Fernandes, por toda ajuda e conhecimento fornecido, de fato um excelente profissional, agradeço também por toda sua paciência ao longo desses anos. Por fim, mas não menos importante, agradeço a uma pessoa chamada Jéssica de Souza Pereira, a qual me acompanhou durante uma trajetória importantíssima do mestrado e de minha vida. Obrigado pela paciência, pela força nos momentos necessários e por intender minha ausência em diversos momentos.

Sem você essa trajetória seria muito mais difícil.



---

# Resumo

---

Em uma rede 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. Tradicionalmente, no planejamento e na operação de uma rede elétrica, esse estudo pode ser desenvolvido por meio da solução numérica de equações não lineares diferenciais, contudo, a acurácia dessa análise é limitada pela capacidade de representação do modelo e pela necessidade da sua constante atualização. Considerando a operação dos sistemas de potência nos dias atuais, com contínuo aumento da demanda de carga bem como da participação de fontes de geração de energia com características intermitentes, essa tarefa tem se tornado cada vez mais desafiadora, aumentando o grau de complexidade do modelo matemático. Por outro lado, o aprimoramento dos sistemas de medição fasorial impulsiona a utilização de técnicas de aprendizado de máquina para a previsão do *status* da estabilidade transitória de uma rede elétrica, dentre as quais as redes neurais têm se destacado. Diante disto, o presente trabalho tem como proposta investigar a utilização de redes neurais artificiais para predição da estabilidade transitória em um sistema elétrico de potência por meio de medidas que podem ser facilmente mensuradas por unidades de medição fasorial, tais como magnitude e ângulo de tensão das barras. Investiga-se na estrutura proposta o menor número de ciclos de medição necessários para realizar a predição, de modo que, o comportamento do sistema (estável ou instável) seja identificado no menor tempo possível, auxiliando na tomada de decisão do operador. 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.

**Palavras-chave:** Previsão da Estabilidade Transitória. Redes Neurais Artificiais. Sin-

crofasores. Técnicas de Aprendizagem de máquina.

---

# Abstract

---

In an electrical network, the assessment and prediction of dynamic safety are essential to avoid interruptions in the supply of electrical energy to consumers, in addition to ensuring that the system operates reliably. Regarding the transient security 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. Traditionally, in the planning and operation of an electrical network, this study can be developed through the numerical solution of nonlinear differential equations, however, the accuracy of this analysis is limited by the capacity of representation of the model and the need for its constant updating. Considering the operation of power systems nowadays, with a continuous increase in load demand as well as the participation of energy generation sources with intermittent characteristics, this task has become increasingly challenging, increasing the degree of complexity of the mathematical model. On the other hand, the improvement of phasor measurement systems boosts the use of machine learning techniques to predict the status of the transient stability of an electrical network, among which neural networks have stood out. In view of this, the present work aims to investigate the use of artificial neural networks to predict transient stability in an electrical power system through measurements that can be easily measured 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 perform the prediction is investigated, so that the behavior of the system (stable or unstable) is identified in the shortest possible time, helping the operator to make a decision. The results obtained in the IEEE 68 bus system show the efficiency of the predictor, which obtained an accuracy of 97.5% in the classification from 6 consecutive cycles of measuring the system response. When only 1 measurement cycle was provided to the predictor, a high accuracy is also achieved 96.1 % by the proposed methodology.

**Keywords:** Prediction of Transient Stability. Artificial Neural Networks. Synchrophasors. Machine Learning Techniques.



---

# Lista de ilustrações

---

Figura 1 – Classificação da estabilidade em um Sistema de Potência. . . . .	28
Figura 2 – Resposta transitória instável do ângulo do rotor dos geradores síncronos em um sistema no período pós-falta. . . . .	31
Figura 3 – Resposta transitória estável do ângulo do rotor dos geradores síncronos em um sistema no período pós-falta. . . . .	32
Figura 4 – Modelo clássico de máquina síncrona . . . . .	33
Figura 5 – Critério das áreas iguais para sistema estável . . . . .	36
Figura 6 – Critério das áreas iguais para sistema instável . . . . .	36
Figura 7 – Resposta transitória do ângulo do rotor dos geradores síncronos em um SEP. . . . .	38
Figura 8 – Neurônio Artificial . . . . .	51
Figura 9 – Arquitetura simples de uma RNA . . . . .	51
Figura 10 – Funções de ativação . . . . .	52
Figura 11 – Arquitetura simples de uma RNA . . . . .	53
Figura 12 – Diagrama da abordagem utilizada. . . . .	55
Figura 13 – Vetor de entrada para as RNAs. . . . .	58
Figura 14 – Diagrama unifilar do sistema IEEE 68 Barras. . . . .	62
Figura 15 – Resultado do índice TSI. . . . .	63
Figura 16 – Resultado do índice TSI sobre a região de fronteira. . . . .	64
Figura 17 – Relação dos casos estáveis e instáveis por tempo de duração da falta trifásica aplicada. . . . .	65
Figura 18 – Boxplot do resultado das 50 RNAs avaliadas para cada modelo de previsão. . . . .	70
Figura 19 – Metodologia . . . . .	91
Figura 20 – Cartão PWF ANAREDE . . . . .	92
Figura 21 – Variação das faltas . . . . .	93
Figura 22 – Cartão ANATEM .STB . . . . .	94
Figura 23 – Aplicação das Faltas . . . . .	94
Figura 24 – Extração de características . . . . .	95

Figura 25 – Variação dos vetores por ciclo . . . . .	96
Figura 26 – Arquitetura de uma RNA . . . . .	97

---

## Lista de tabelas

---

Tabela 1 – Comparação entre as abordagens. . . . .	46
Tabela 2 – Matriz de Confusão . . . . .	59
Tabela 3 – Modos eletromecânicos do sistema de teste . . . . .	62
Tabela 4 – Dimensão da camada de entrada da RNA de acordo com o número de ciclos de medição consecutivos necessários. . . . .	65
Tabela 5 – Teste de arquitetura das RNAs 8 ciclos com 1 camada. . . . .	66
Tabela 6 – Teste de arquitetura das RNAs 8 ciclos com 2 camadas. . . . .	67
Tabela 7 – Desvio padrão das RNAs de 1 e 2 camadas para a RNA de 8 ciclos. . .	68
Tabela 8 – Quantidade de neurônios por camada. . . . .	68
Tabela 9 – Acurácias e desvio padrão absoluto dos 50 treinamentos realizados para cada modelo de predição. . . . .	69
Tabela 10 – Teste de arquitetura das RNAs 7 ciclos . . . . .	82
Tabela 11 – Teste de arquitetura das RNAs 6 ciclos . . . . .	83
Tabela 12 – Teste de arquitetura das RNAs 5 ciclos . . . . .	84
Tabela 13 – Teste de arquitetura das RNAs 4 ciclos . . . . .	85
Tabela 14 – Teste de arquitetura das RNAs 3 ciclos . . . . .	86
Tabela 15 – Teste de arquitetura das RNAs 2 ciclos . . . . .	87
Tabela 16 – Teste de arquitetura das RNAs 1 ciclo . . . . .	88
Tabela 17 – Desvio padrão das RNAs de 1 e 2 camadas. . . . .	89





---

# Lista de siglas

---

**ANN** *Artificial Neural Network*

**BCU** *Boundary Controlling Unstable Equilibrium Point*

**CEPEL** *Centro de Pesquisas de Energia Elétrica*

**CCT** *Critical Clearing Time*

**DT** *Decision Tree*

**ELM** *Extreme learning machine*

**GA** *Genetic Algorithm*

**IPSO** *improved particle swarm optimization algorithm*

**IRF** *Iterative Random Forest*

**MAE** *Erro Absoluto Médio*

**MAE** *Mean Absolute Error*

**MLP** *Multilayer perceptron*

**MSVM** *Multiclass Support Vector Machine*

**NPCC** *Northeast Power Coordinating Council*

**PEBS** *Potential Energy Boundary Surface*

**PSO** *Particle Swarm Optimization*

**PMU** *Phasor Measurement Unit*

**RNA** *Rede Neural Artificial*

**RBF** *Radial Basis Function*

**SCADA** *Supervisory Control and Data Acquisition*

**SEP** *Sistema Elétrico de Potência*

**SVM** *Support Vector Machine*

**TSA** *Transient Security Assessment*

**TSI** *Transient Instability Index*

**TSO** *Transmission System Operator*

**WAMS** *Wide-Area Monitoring System*

**WECC** *Western Electricity Coordinating Council*

---

# Sumário

---

1	INTRODUÇÃO . . . . .	19
1.1	Predição do Sistema Elétrico no Período Pós-Falta a Partir de Dados de Medição . . . . .	21
1.2	Objetivos . . . . .	24
1.3	Organização dos capítulos . . . . .	24
2	AVALIAÇÃO DA ESTABILIDADE TRANSITÓRIA DE UM SISTEMA DE POTÊNCIA . . . . .	27
2.1	Introdução ao Conceito de Estabilidade e as suas Principais Categorias . . . . .	27
2.2	Estabilidade Transitória: Conceitos Fundamentais e as princi- pais Técnicas para Avaliação de Potenciais Instabilidades . . . .	29
2.2.1	Técnicas para estudo da estabilidade transitória . . . . .	32
3	REVISÃO BIBLIOGRÁFICA . . . . .	41
3.1	Técnicas de Aprendizagem de Máquina aplicadas no estudo da Estabilidade Transitória . . . . .	41
3.2	Avaliação da Estabilidade Transitória a partir de Redes Neurais	43
3.3	Análise Geral . . . . .	46
4	MÉTODO PROPOSTO PARA PREDIÇÃO DA ESTABILI- DADE TRANSITÓRIA . . . . .	49
4.1	Redes Neurais Artificiais . . . . .	49
4.1.1	<i>Perceptron</i> Multicamadas . . . . .	53
4.2	Abordagem proposta para predição da estabilidade transitória	54
4.2.1	Formação do banco de dados sobre grandes perturbações diante do sis- tema teste . . . . .	55
4.3	Treinamento e Validação do Classificador a base de Rede Neu- rais Artificiais. . . . .	57

4.3.1	Métodos de validação . . . . .	58
<b>5</b>	<b>RESULTADOS . . . . .</b>	<b>61</b>
5.1	Sistema Teste . . . . .	61
5.2	Banco de dados do sistema teste de 68 Barras . . . . .	63
5.3	Resultado da classificação da estabilidade transitória de acordo com o conjunto de ciclos de medição . . . . .	64
5.3.1	Análise Estatística da Classificação da Estabilidade Transitória . . . . .	68
5.3.2	Discussão . . . . .	69
<b>6</b>	<b>CONCLUSÕES . . . . .</b>	<b>73</b>
	Conclusão . . . . .	74
	<b>REFERÊNCIAS . . . . .</b>	<b>75</b>

## **APÊNDICES 79**

<b>APÊNDICE A</b>	<b>– DEFINIÇÃO DA ARQUITETURA DAS REDES NEURAIS PARA CADA VETOR DE ENTRADA</b>	<b>81</b>
<b>APÊNDICE B</b>	<b>– METODOLOGIA PROPOSTA . . . . .</b>	<b>91</b>
B.1	1º Passo: Encontrar os pontos de máxima e mínima operação do sistema teste sem que o mesmo perda a estabilidade . . . . .	92
B.2	2º Passo: variação dos pontos de aplicação de falta e duração .	93
B.3	3º Passo: Extração de característica sobre a estabilidade do sistema . . . . .	95
B.4	4º passo: Treinamento das RNAs . . . . .	95

## Capítulo 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 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, diversos estudos são desenvolvidos pelos centros de operação, para garantir uma margem suficiente de segurança durante a operação com diferentes condições de carregamento e de topologia de um sistema de potência. No entanto, como pontuado por Morison, Lei Wang e Kundur (2004), nas análises realizadas, inclusive de situações de contingências, não é possível prever todas as eventuais falhas que um sistema possa estar sujeito e suas possíveis condições de operação, as quais tem se tornado mais complexas tendo em vista as recentes alterações na rede (MIHAILESCU; OSSOWSKI; KLUSCH, 2017). Nesse sentido, estudos para predição de potenciais instabilidades da rede a partir do monitoramento da operação do sistema têm se intensificado (YU et al., 2018).

Diante das informações do monitoramento em tempo real, o operador poderá antever riscos e acionar as devidas medidas de segurança, permitindo que a energia elétrica seja fornecida continuamente e sem interrupções (YU et al., 2018). Por exemplo, uma previsão rápida de potenciais instabilidades resulta em um maior tempo hábil para o operador poder coordenar as ações de controle.

Recentemente, com o aperfeiçoamento dos sistemas de medição fasorial sincronizado, e com a formação de grandes áreas de monitoramento (do inglês, *Wide Area Measurement System* - WAMS), 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 Sistemas 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 *machine learning* sejam utilizadas para investigação, previsão e análise da operação em uma rede elétrica (Hashiesh et al., 2012; Phadke et al., 2008).

Por exemplo, em Liu et al. (2014), são desenvolvidos dois modelos preditivos a base de árvore de decisão responsáveis por avaliar tanto a segurança dinâmica de um sistema interconectado quanto como definir a ação de controle correspondente para que o sistema não opere em condição de contingência. Os dados monitorados ao longo de todo o sistema por PMUs são enviados ao primeiro modelo preditivo, o qual identifica potenciais cenários de operação não segura. Caso uma situação de alerta seja detectada, o segundo modelo identifica a ação mais adequada para que o sistema não opere em situação de contingência, apoiando a decisão do operador.

No contexto da avaliação da segurança dinâmica de um SEP, este trabalho têm como foco de estudo uma de suas categorias, a avaliação da segurança transitória (do inglês, *Transient Security Assessment*). Nesta área investiga-se a estabilidade angular da rede frente a grandes perturbações, também denominada estabilidade transitória.

A estabilidade de um sistema refere-se à sua capacidade em permanecer em um estado de equilíbrio sob condições normais de operação e, após ser submetido a um distúrbio, conseguir recuperar um estado de equilíbrio, com a maioria das variáveis limitadas para que o sistema todo permaneça intacto (Kundur et al., 2004). Em específico, à estabilidade transitória refere-se a capacidade do sistema manter seus geradores operando em sincronismo mesmo quando o sistema é submetido a grandes perturbações, como curtos-circuitos ou perdas de linha de transmissão. De forma sucinta, a estabilidade transitória analisa o comportamento dos geradores síncronos conectados no sistema de potência durante os primeiros segundos após a ocorrência de uma grande perturbação, analisando a variação angular dos rotores existente entre eles (Kundur et al., 2004).

Caso os geradores não mantenham o sincronismo após uma grande perturbação, caracterizando o comportamento de um sistema instável, tal comportamento pode resultar em interrupções em cascata, ilhamento não intencional de porções do sistema, além da propagação de *blackouts* ao longo do sistema.

Tradicionalmente, a estabilidade transitória pode ser investigada 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, principalmente quando se avalia um sistema de grande dimensão (Kundur et al., 2004).

Portanto, este estudo é normalmente aplicado em análises que possam ser conduzidas de maneira *offline*, normalmente, no planejamento da operação da rede elétrica.

Ademais, conforme pontuado por (ARIFF; PAL; SINGH, 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, limitando a sua aplicação nesse contexto.

Desde a década de 80, métodos baseados em função de energia, denominados como métodos diretos, também têm sido amplamente aplicados para avaliação da estabilidade transitória (Hiskens; Hill, 1989). Tais métodos não exigem a solução numérica do conjunto de equações diferenciais que representam todo o sistema em análise, sendo essa vantagem que resulta o nome direto ao método. Além de avaliar a estabilidade dos pontos de equilíbrio, o método também fornece um caminho para estabelecer a área de atração do sistema no pós-falta. Contudo, estabelecer uma função de energia não é uma tarefa simples e como evidenciado por Yusof, Rogers e Alden (1993), essa abordagem pode apresentar algumas restrições quando aplicada em sistemas de grande dimensão.

Considerando o ambiente rico em dados com a evolução dos sistemas de medição fasorial sincronizado, técnicas de mineração de dados e aprendizado de máquina tornam-se alternativas interessantes para lidar com problemas de operação em tempo real no sistema elétrico de potência (Yu et al., 2018; REN C., 2018) e para predição da estabilidade transitória.

Nesse contexto apresentado, esse trabalho tem como finalidade contribuir nessa área, desenvolvendo uma ferramenta para prever a estabilidade transitória do sistema com o auxílio de uma técnica de aprendizado de máquina, as Redes Neurais Artificiais (RNAs) e fornecendo suporte à tomada de decisão do operador.

## 1.1 Predição do Sistema Elétrico no Período Pós-Falta a Partir de Dados de Medição

Diante das dificuldades pontuadas anteriormente e da disponibilidade de dados resultante do aprimoramento dos sistemas de medição, soluções baseadas em aprendizado de máquina tais como lógica Fuzzy, árvores de decisão (DT) e redes neurais artificiais (RNA) têm sido utilizadas para classificação da estabilidade transitória na literatura recente (Yu et al., 2018; REN C., 2018). A partir de simulações *offline*, as técnicas de aprendizagem de máquina fazem um mapeamento entre sinais medidos na rede elétrica, tais como a magnitude e o ângulo da tensão terminal de um gerador e o estado de operação da rede, no que diz respeito à estabilidade transitória. Dessa forma, um modelo de predição é es-

tabelecido, o qual é capaz de prever se o sistema irá operar de forma estável ou instável dado um novo conjunto de dados medidos (Hashiesh et al., 2012).

Por exemplo, os autores Nohara, Assis e Valentini (2009) desenvolveram um preditor de estabilidade transitória a partir de um sistema neuro-fuzzy. A metodologia consiste na aplicação de uma rede neural para estimar um índice de desempenho dinâmico que fornece o máximo desvio angular entre os geradores conectados no sistema teste. Com esse objetivo, uma RNA é treinada a partir de medições do ângulo do rotor de cada gerador síncrono conectado no sistema, bem como da potência de aceleração no período em falta e de potência resultante após a eliminação do distúrbio. Em seguida, é realizada uma classificação fuzzy com base nesse índice, definindo o sistema em seguro, inseguro ou em uma faixa de incerteza, denominada como “segurança duvidosa”. Os resultados obtidos no sistema brasileiro de 45 barras e 10 geradores, identificam com uma acurácia de 70,6% o cenário do sistema teste após uma grande perturbação.

Já no trabalho realizado por Guo e Milanović (2016) duas técnicas distintas são aplicadas para definir o *status* de estabilidade da rede. Um modelo baseia-se em árvores de decisão, para qual são testados algoritmos diferentes para criação da árvore como o *Boosting* e o *Random Florest*. A segunda técnica aplicada utiliza a máquina de vetor de suporte multi-classe (do inglês, *Multiclass Support Vector Machine* - MSVM). A classificação da estabilidade é realizada a partir da medida do ângulo do rotor dos geradores conectados no sistema em estudo. A acurácia de ambos os métodos foi superior a 89% para 10 ciclos de medição dos dados no sistema IEEE 68 barras.

Dentre as técnicas de aprendizagem de máquinas, métodos baseados em redes neurais artificiais como em Yu et al. (2018), Hashiesh et al. (2012), Ren C. (2018) apresentam uma elevada precisão na classificação da estabilidade, atingido um índice de acurácia superior a 97%.

Por exemplo, na pesquisa desenvolvida por (HASHIESH et al., 2010) é proposta uma rede neural artificial para a previsão da estabilidade transitória a partir de medidas das tensões e ângulos das barras por PMUs. O sistema utilizado para testes é o sistema de energia egípcio (EPS), no qual os resultados obtidos pelo sistema inteligente proposto atingiram uma acurácia de 91%.

Em Tan et al. (2017) um TSA é proposto a base de redes neurais convolucionais (do inglês, *Convolutional Neural Networks* - CNN). A abordagem propõe o aprendizado representacional do TSA por meio de uma CNN formada por autoencoders empilhados (do inglês, *stacked autoencoders* - SAEs). Esta técnica de aprendizado de máquina utiliza como dados de entrada para a predição da estabilidade os ângulos do rotor, potência de aceleração e desaceleração do rotor e velocidade do rotor nas barras de geração. O sistema teste utilizado para averiguar o desempenho do preditor é o sistema de potência de 39 barras, o sistema *New England* reduzido. Os resultados obtidos pelo método proposto chegaram a uma acurácia de 97%.



Além da acurácia e da disponibilidade das amostras necessárias para a classificação, um 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.

Por exemplo, em Hashiesh et al. (2012) um sistema de RNA do tipo *feed-forward* de duas camadas é proposta para prever a estabilidade de um sistema de energia elétrica a partir de medidas do ângulo do rotor de cada gerador conectado no sistema. Para os testes da RNA apresentada foram simuladas diversas faltas no sistema em diferentes linhas e com diversos tempos de duração das faltas. Os resultados apresentados conseguiram prever 98% dos casos testados para uma medição de 15 ciclos após a eliminação da falta. Além da grande quantidade de ciclos, os autores utilizam a medida do ângulo do rotor como entrada do modelo, que não é uma medida fornecida pelas PMUs, tornando assim mais difícil a predição realizada pelo método proposto.

Em Yu et al. (2018), o sistema inteligente proposto para a predição da estabilidade transitória é uma arquitetura de redes neurais recorrentes, a memória de longa curta duração (do inglês, *long short-term memory* - LSTM). Para o treinamento desta rede foram utilizados como dados de entrada, fasores de tensão de sequência positiva. Os dados de saída são obtidos a partir de um índice de estabilidade, responsável por averiguar a estabilidade do sistema como estável ou instável. Para avaliar a acurácia do método, foram realizados testes em 3 sistemas distintos: o primeiro sistema com 10 máquinas, um segundo sistema com 17 máquinas e o terceiro com 50 máquinas interligadas. O método conseguiu prever com acurácia superior a 98% a estabilidade do sistema, exigindo apenas 5 ciclos do sinal medido.

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 por meio da quantidade de ciclos de medição necessárias.

Com esse propósito, inicialmente é formado um banco de dados, contendo simulações com diferentes cenários de operação do sistema elétrico em análise. Posteriormente, diferentes estruturas de redes neurais são avaliadas para definir a arquitetura mais adequada de acordo com a dimensão do vetor de entrada do modelo de predição, ou seja, da quantidade de ciclos de medição necessários para realizar a classificação da estabilidade

do sistema. Uma vez definida a arquitetura da rede neural, uma análise estatística é aplicada para verificar a acurácia atingida pelo método proposto.

## 1.2 Objetivos

Diante da disponibilidade de dados que podem ser mensurados pelas grandes áreas de monitoramento e, considerando a necessidade de prever o comportamento dinâmico de um sistema de potência após a ocorrência de uma perturbação, esse trabalho tem como objetivo geral:

- Desenvolver um modelo de predição que consiga identificar o *status* de estabilidade de um sistema de potência, a partir de dados amostrados por PMUs, tais como a magnitude e o ângulo da tensão das barras de geração. Pretende-se realizar a predição de estabilidade transitória, a partir de redes neurais artificiais, utilizando a menor quantidade de ciclos possível.

Para a realização desse trabalho, os seguintes objetivos específicos devem ser atendidos:

- Construção de um amplo banco de dados com comportamento dinâmico do sistema teste avaliado, fornecendo grande variedade de condições de operação para a análise da estabilidade transitória.
- Avaliar os desempenhos das RNAs como preditor da estabilidade transitória do sistema, quando submetida a diversas condições de operação.
- Investigar 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 pela quantidade de ciclos de medição necessária.

## 1.3 Organização dos capítulos

- **Capítulo 2:** Neste capítulo são apresentados os aspectos fundamentais do estudo da estabilidade angular do rotor a grandes perturbações, fornecendo o suporte teórico necessário para caracterizar o comportamento dinâmico do sistema após um distúrbio.
- **Capítulo 3:** A fim de evidenciar a pesquisa feita, esse capítulo possui uma breve revisão bibliográfica sobre trabalhos que investigam a estabilidade transitória a partir de técnicas de aprendizagem de máquinas, destacando as principais características das pesquisas desenvolvidas na literatura correlata.

- **Capítulo 4:** A metodologia proposta para a construção do modelo de predição de estabilidade transitória é apresentada neste capítulo. As principais etapas que compõem a estrutura posposta, desde a preparação do banco de dados até o treinamento e validação do modelo também são abordadas nesse capítulo.
- **Capítulo 5:** Os resultados obtidos para verificar a eficiência das redes neurais são discutidos nesse capítulo.
- **Capítulo 6:** As conclusões em relação à pesquisa desenvolvida e dos seus resultados são discutidos nesse capítulo. Sugestões para futuras melhorias serão apresentadas com base nos resultados obtidos.



## Capítulo 2

---

# Avaliação da Estabilidade Transitória de um Sistema de Potência

---

## 2.1 Introdução ao Conceito de Estabilidade e as suas Principais Categorias

A segurança dinâmica de um sistema elétrico de potência está relacionada com a capacidade do mesmo em atender à demanda de energia requerida pelos seus consumidores dentro de limites aceitáveis de tensão e frequência mesmo na presença de defeitos ou perturbações de forma a garantir a continuidade da prestação de serviço (Kundur et al., 2004; ALBERTO; BRETAS, 2000; Balu et al., 1992).

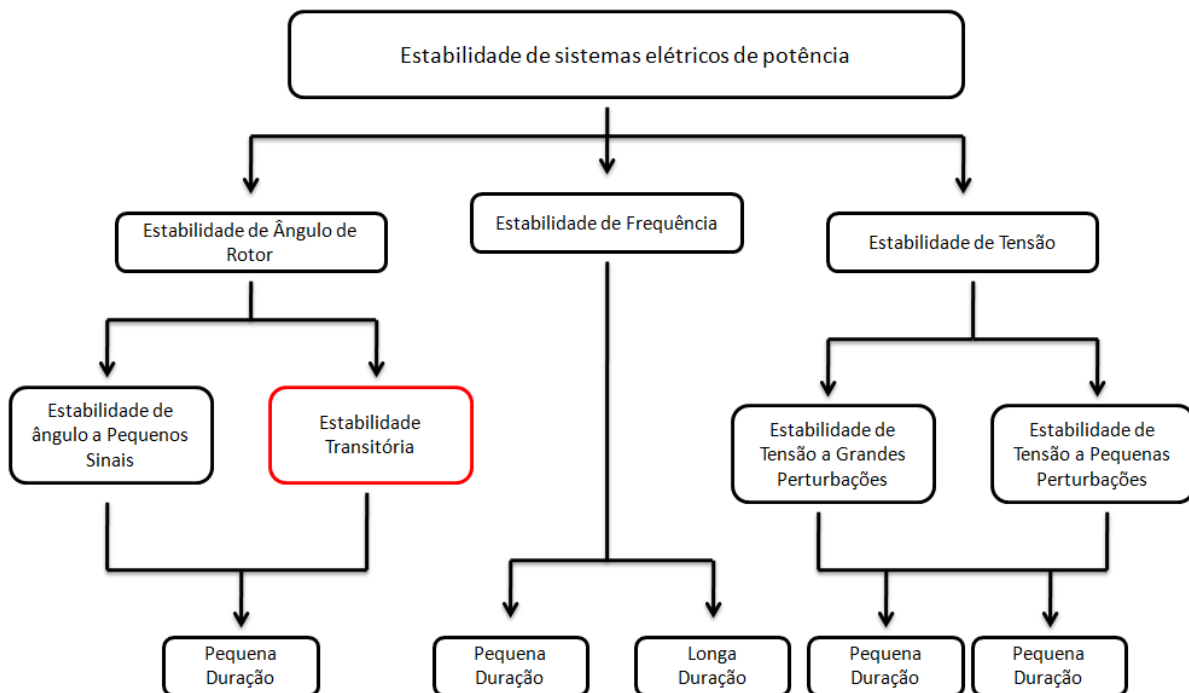
Segurança e estabilidade de um SEP são termos altamente relacionados, já que estabilidade é premissa para segurança da operação de um SEP. Contudo, o conceito de segurança é mais amplo, avaliando além da estabilidade de uma rede, a integridade do sistema e a avaliação do estado de equilíbrio da rede do ponto de vista das variações de carga, violações dos níveis de tensão e frequência (Kundur et al., 2004).

Diferentes são as causas de perturbações ou defeitos que um sistema possa estar sujeito, como curtos-circuitos, entrada e saída de cargas de grande porte, rompimentos de linhas de transmissão, entre outros. De acordo com a severidade dessa perturbação e o ponto de operação da rede quando sujeito a esse distúrbio, poderá ocorrer um afastamento do sistema do seu ponto de operação original. Segundo Alberto e Bretas (2000), os estudos de estabilidade analisam o comportamento transitório do sistema após tais perturbações, avaliando se o sistema irá reestabelecer o ponto original ou atingir um novo ponto de operação e quais os procedimentos necessários para que isso aconteça.

A análise da estabilidade em um SEP pode ser dividida em três categorias principais relacionadas com natureza física em que se manifesta a instabilidade, a saber: estabilidade do ângulo do rotor, estabilidade da frequência e estabilidade da tensão (Kundur et al., 2004). As classes de estabilidade de tensão e estabilidade do ângulo do rotor são compos-

tas por subcategorias relacionadas com tamanho da perturbação avaliada (pequena ou grande perturbação), visto que a magnitude do distúrbio influencia no método de cálculo e previsão da estabilidade. Por fim, os dispositivos, os processos e intervalo de tempo que devem ser considerados para avaliar a estabilidade (curto ou longo prazo), também resultam em novas subcategorias na definição do conceito de estabilidade. A Figura 1 mostra as três categorias e a subdivisão de cada uma delas com destaque para a estabilidade transitória, foco de pesquisa deste trabalho, associada à classe da estabilidade angular do rotor.

Figura 1 – Classificação da estabilidade em um Sistema de Potência.



Fonte: adaptado de (Kundur et al., 2004).

Com relação às três categorias principais, a estabilidade de tensão em sistema interconectado está associada à capacidade de manutenção das tensões em todas as barras do sistema dentro de limites aceitáveis, tanto em condições normais de operação bem como após sofrer um distúrbio. Para isso, o sistema deve ser capaz de manter ou reestabelecer o equilíbrio entre a potência fornecida pelos geradores e a demanda das cargas interligadas no sistema. A instabilidade de tensão se manifesta quando ocorre queda ou aumento progressivo e descontrolado das tensões de alguns barramentos. Um possível resultado da instabilidade da tensão é a perda de carga em uma área ou o desligamento de linhas de transmissão.

Já no estudo de estabilidade da frequência avalia-se a habilidade de um sistema de potência em manter uma frequência aceitável após ser submetido a uma perturbação resultante de um desequilíbrio significativo entre a geração de energia e a demanda das cargas. Conforme pontuado por (GOMEZ-EXPOSITO; CONEJO; CANIZARES, 2011),

se o sistema entra em uma condição de frequência instável, poderá ocorrer uma diminuição abrupta da frequência ou surgimento de oscilações sustentadas, resultando no desligamento de unidades geradoras e/ou cargas (KUNDUR, 1994).

Por definição, a estabilidade do ângulo do rotor refere-se à habilidade das máquinas síncronas de um sistema interconectado permanecerem em sincronismo após serem submetidas a um distúrbio (Kundur et al., 2004). A perturbação leva ao desequilíbrio entre a potência mecânica de entrada e a potência elétrica de cada gerador. Devido a esse desequilíbrio temporário, que pode originar um excesso ou *déficit* de energia nas máquinas, os rotores das máquinas conectadas no sistema oscilam um contra os outros, trocando energia por meio das linhas de transmissão. Os problemas de estabilidade ficam, então, evidentes por meio das oscilações na potência/frequência de alguns geradores, que não irão operar de forma síncrona com os demais (GOMEZ-EXPOSITO; CONEJO; CANIZARES, 2011).

Conforme a severidade da perturbação que o sistema foi exposto, a estabilidade angular do rotor subdivide-se em duas classes: pequenas perturbações e grandes perturbações. As pequenas perturbações estão relacionadas a variações de cargas que não afastam significativamente o sistema de seu ponto de equilíbrio original. Desta maneira é possível realizar a linearização das equações algébrico-diferenciais que representam o SEP em torno de um ponto de equilíbrio, essa linearização é feita por meio da expansão em série de Taylor (KUNDUR, 1994). De posse das equações linearizadas torna-se possível obter informações qualitativas a respeito da estabilidade do sistema em torno do ponto de equilíbrio em que as equações foram linearizadas, a partir do cálculo dos autovalores e autovetores associados à matriz de estados do modelo.

No entanto, quando o sistema é submetido a uma grande perturbação, responsável por afastar de forma significativa a trajetória de um sistema dinâmico do seu ponto de equilíbrio, as técnicas baseadas em modelos linearizados passam a não ser completamente adequadas. Assim, a resposta dinâmica do sistema será dominada pelas não linearidades do sistema de potência, resultando em excursões de elevada amplitude do ângulo dos geradores (THEODORO, 2017). Nesse cenário, a estabilidade angular do rotor é avaliada na subcategoria de estabilidade angular do rotor associado à grande perturbações, à estabilidade transitória. Os principais aspectos envolvidos no estudo da estabilidade transitória são detalhados na seção em sequência.

## 2.2 Estabilidade Transitória: Conceitos Fundamentais e as principais Técnicas para Avaliação de Potenciais Instabilidades

Um sistema de energia elétrica é altamente não linear e sua operação acontece diante de um cenário de constantes mudanças, tais como, variações de cargas, ocorrência de curtos-

circuitos e perdas de linhas de transmissão. Quando submetido a uma perturbação, o comportamento dinâmico do sistema no pós-falta irá depender da condição inicial da operação bem como da natureza da perturbação.

Segundo Kundur et al. (2004), a estabilidade transitória refere-se à capacidade dos geradores, conectados ao SEP, manterem o sincronismo quando submetidos a distúrbios de natureza severa, ou seja, uma grande perturbação. Investiga-se o comportamento da resposta do ângulo do rotor dos geradores síncronos após o sistema ser submetido a uma perturbação de severa magnitude, tal como a perda de uma linha de transmissão, ou saída de um grande gerador. Caso o ângulo do rotor e velocidade dos geradores de um sistema permaneçam oscilando de forma síncrona após a eliminação da falta, de modo que, as diferenças entre suas velocidades e ângulos de fase permaneçam limitadas, o sistema é classificado como transitoriamente estável. No entanto, se após a eliminação do defeito, um gerador ou um grupo de geradores não oscila de forma síncrona com os demais, o sistema é transitoriamente instável.

Um dos fatores determinantes nesse problema é a relação entre a potência de saída das máquinas em relação à variação do ângulo dos respectivos rotores das máquinas (Kundur et al., 2004). Em regime permanente, há equilíbrio entre o torque mecânico e o eletromagnético em cada gerador, de forma que a velocidade angular permanece constante. Quando o sistema sofre uma perturbação, há o desequilíbrio entre os torques, levando à aceleração ou desaceleração dos rotores das máquinas síncronas. Se um gerador gira temporariamente com uma velocidade angular superior a de uma outra máquina síncrona, há um aumento da diferença angular entre as máquinas, a qual pode resultar em uma transferência de carga da máquina mais lenta para a máquina mais rápida, de acordo com a curva de relação entre o ângulo e a potência. Essa relação entre potência e ângulo de cada máquina é altamente não linear, e quando ultrapassa um certo limite o sistema não consegue corrigir a relação entre potência e ângulo, levando assim o sistema para a instabilidade. Logo a instabilidade ocorre se o sistema não puder absorver a energia cinética correspondente a essas diferenças de velocidade do rotor.

A capacidade do sistema em manter/restabelecer o equilíbrio entre o torque mecânico e eletromagnético de cada gerador do sistema dependerá de alguns fatores, dentre os quais pode-se citar (KUNDUR, 1994): carregamento dos geradores; potência de saída do gerador durante a perturbação; tempo necessário para eliminação da perturbação; a reatância da transmissão no pós-falta, período que se inicia após a eliminação da falta do sistema; a inércia do gerador. Quanto maior a inércia da máquina, mais lenta é a variação do ângulo. Isso reduz o acúmulo de energia cinética na falta e conseqüentemente, a probabilidade de ocorrência da instabilidade.

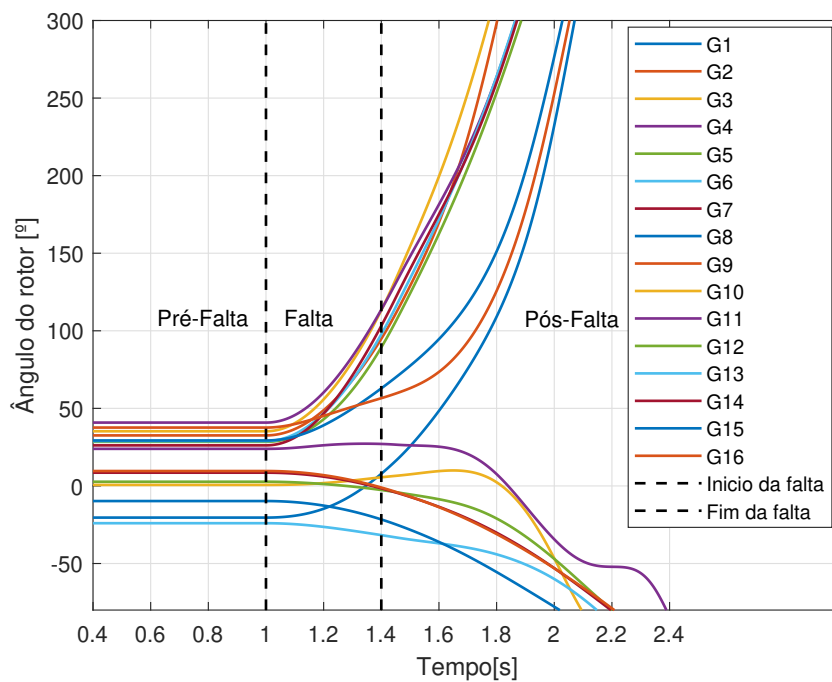
Para exemplificar o comportamento da rede quando submetido a uma perturbação, as Figuras 2 e 3 exibem a resposta transitória do ângulo do rotor de geradores síncronos conectados em um sistema-teste, composto por 16 geradores. A Figura 2 mostra a resposta



angular do rotor dos geradores síncronos desse sistema teste, quando o mesmo é submetido a uma perturbação com duração de 0,4 segundos. Note que o sistema apresenta um comportamento instável, visto que os geradores perdem o sincronismo, ocorrendo alta excursão da amplitude do ângulo de seus rotores. Já na Figura 3 é possível observar um sistema estável, note que os geradores oscilam de forma síncrona, depois da eliminação da falta, caracterizando a resposta de um sistema estável.

É importante mencionar também o intervalo de tempo de interesse para o estudo da estabilidade transitória, o qual é usualmente de 3 a 5 segundos após a eliminação da falta, período em que a resposta dos controladores não consegue provocar efeitos significativos no comportamento do sistema. Para grandes sistemas de potência com modos de oscilação entre áreas, este intervalo pode ser estendido para 10 a 20 segundos (Kundur et al., 2004).

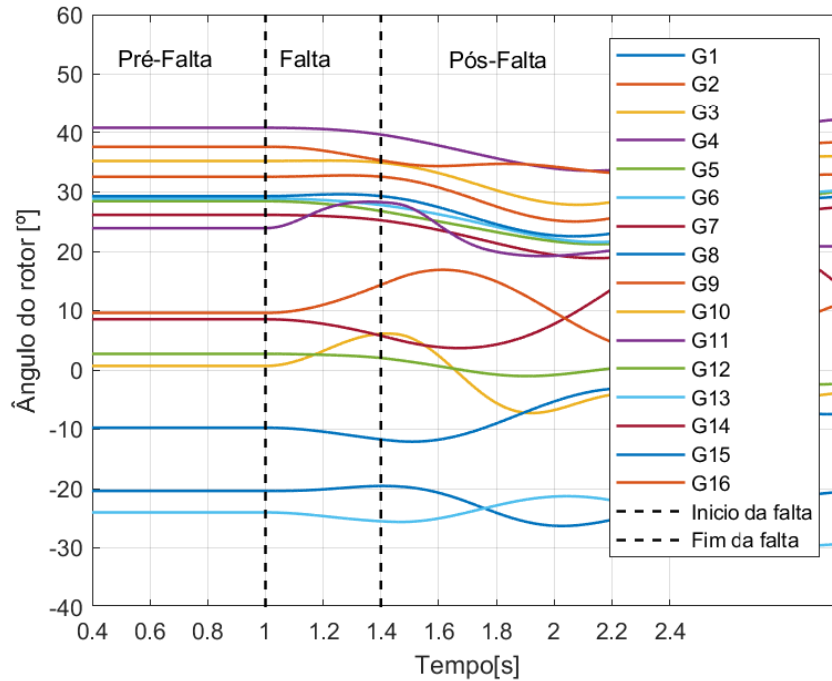
Figura 2 – Resposta transitória instável do ângulo do rotor dos geradores síncronos em um sistema no período pós-falta.



Fonte: Autoria Própria

É importante que o sistema elétrico opere com margem de segurança em torno de suas variáveis de operação, como tensão e ângulos de seus barramentos, além dos ângulos dos rotores de seus geradores, para que assim o sistema seja capaz de reestabelecer uma ponto de operação estável mesmo após ter sido submetido a perturbação. Para isso é necessário que o sistema seja continuamente monitorado, levando informações como sobrecarregamento da rede e grandes variações de carga para os operadores. Caso o sistema chegue à instabilidade, ele pode sofrer o ilhamento não intencional, provocar interrupções em cascata ocasionando a propagação de *blackouts*.

Figura 3 – Resposta transitória estável do ângulo do rotor dos geradores síncronos em um sistema no período pós-falta.



Fonte: Autoria Própria

Para avaliar se o sistema irá operar de forma estável ou instável após ocorrência de uma perturbação, existem técnicas consolidadas na literatura que podem ser aplicadas de maneira *offline*. Uma breve introdução a essas técnicas bem como a apresentação do índice de estabilidade utilizado nesse trabalho para classificação da estabilidade são apresentados na seção abaixo (KUNDUR, 1994).

### 2.2.1 Técnicas para estudo da estabilidade transitória

Na prática, o sistema elétrico de potência apresenta estrutura complexa a qual pode ser representada por um conjunto de equações algébrico-diferenciais descrito pelas seguintes equações (KUNDUR, 1994):

$$\dot{x} = f(x, u, z) \quad (1)$$

$$0 = h(x, u, z) \quad (2)$$

$$y = g(x, u, z) \quad (3)$$

em que  $x \in \mathbb{R}^n$  é um vetor que contém as variáveis de estado do sistema,  $u \in \mathbb{R}^p$  é um vetor composto pelas entradas de controle,  $y \in \mathbb{R}^q$  é um vetor com as saídas do sistema e por fim  $z \in \mathbb{R}^m$  corresponde a um vetor com as variáveis algébricas.



$$T_r = J * \ddot{\Theta} \quad (4)$$

em que:

- $J$  é o momento de inércia, dado em  $\text{kg} \times \text{m}^2$ .
- $\theta$  é o ângulo mecânico do rotor com relação à referência fixa, dado em radianos.
- $T_r$  é o torque resultante, fornecido em  $\text{N} \times \text{m}$ .

O torque  $T_r$  é a diferença entre os torques mecânico e elétrico. Para que o sistema atue de forma equilibrada a diferença entre eles deve ser zero, de modo a garantir que a máquina não acelere ou desacelere. Para uma máquina atuando como gerador, ambos os torques são positivos. O  $T_m$  atua como entrada fazendo a máquina acelerar e o  $T_e$  atua como saída fazendo a máquina desacelerar (BRETAS; ALBERTO, 2000). Sendo assim:

$$T_r = T_m - T_e \quad (5)$$

No entanto, o ângulo  $\theta$  da Figura 4 em relação a uma referência estacionária, resultando em ângulo que é variável com o tempo, cuja alteração é descrita por uma função senoidal. Assim é de interesse utilizar outro tipo de sistema de referência para evitar esse obstáculo, desta forma é adotado um sistema de referência girante com velocidade síncrona  $\omega_s$ . A relação entre o ângulo  $\theta$  e o medido a partir da referência girante é dada por:

$$\theta(t) = (\omega_s t + \alpha) + \delta_m(t) \quad (6)$$

em que:

- $(\omega_s t + \alpha)$  – referência girante à velocidade síncrona;
- $\alpha$  – ângulo de defasagem entre a referência fixa e a referência girante no tempo  $t = 0$  ;
- $\delta_m(t)$  – ângulo mecânico formado entre o rotor a e referência girante.

Trabalhando com uma referência girante, é possível escrever a equação (4) *swing* da seguinte forma:

$$J\ddot{\delta}_m = T_m - T_e \quad (7)$$

É de interesse trabalhar com potência elétrica no lugar de torque, pois o torque é uma grandeza de complicada medição, diferente da potência elétrica que pode ser medida

por meio de grandezas puramente elétricas. Desta forma a equação diferencial escrita em termos de potência, já considerando a transformação com grandezas por unidade (p.u) é:

$$M_i \ddot{\delta}_i = P_{mi} - P_{ei} \quad [p.u] \quad (8)$$

em que  $P_{mi}$  corresponde à potência mecânica em p.u. injetada na  $i$ -ésima máquina e  $P_{ei}$  refere-se a potência elétrica em p.u. entregue a rede pela  $i$ -ésima máquina. Esta equação é chamada equação de *swing* do sistema, responsável por descrever o comportamento da velocidade e do ângulo do rotor dos geradores síncronos.

Na avaliação da estabilidade transitória por análise de simulações no domínio do tempo, o conjunto de equações algébrico-diferenciais que descrevem o sistema teste é resolvido por meio de integração numérica, como o trapezoidal implícito e o método de Runge-Kutta. Na escolha de um método de integração alguns fatores são considerados, por exemplo, fatores de estabilidade numérica, desempenho na presença de descontinuidade, quantidade de pontos, dentre outros. No caso da previsão das equações apresentadas os métodos mais utilizados são Runge Kutta e Euler, pois o problema apresentado tem como característica ser um problema de ponto inicial (SILVA, 2013).


Uma outra forma de avaliar a estabilidade transitória é por meio de métodos energéticos. Os métodos energéticos Lyapunov, PEBS (do inglês, *Potential Energy Boundary Surface* - PEBS) e BCU (do inglês, *Boundary Controlling Unstable Equilibrium Point* - BCU) são os mais utilizados (ALBERTO; BRETAS, 2000). Todos estes métodos apresentam abordagens diretas para a definição de estabilidade transitória (YU et al., 2018).

O método direto ou energético mais conhecido para avaliar a estabilidade do sistema é o critério das áreas iguais, sendo um dos primeiros métodos que surgiu para resolver o problema de estabilidade de maneira rápida (ALBERTO; BRETAS, 2000). Esse critério tem como base algumas hipóteses: a primeira delas é que a potência mecânica de entrada das máquinas é constante no intervalo de tempo avaliado; a segunda desconsidera o efeito dos enrolamentos amortecedores na modelagem da máquina e a terceira afirma que as máquinas síncronas podem ser representadas por uma tensão constante atrás de sua reatância transitória (modelo clássico) nessa análise. De modo bem simplificado, o critério das áreas iguais menciona que o sistema será estável se após uma perturbação a área de desaceleração na curva de relação entre potência e ângulo for maior que a área de aceleração. Considerando o ângulo de torque mecânico e elétrico entre uma máquina síncrona e o barramento infinito.

A Figura 5 ilustra uma situação em que o critério das áreas iguais classifica o sistema como estável, pois a área de desaceleração  $A2$  é maior que a área de aceleração  $A1$ . Neste cenário, o ângulo  $\delta_{max}$  atingindo pela máquina após a remoção de um curto trifásico aplicado em seus terminais resulta em uma potência elétrica superior a mecânica. Assim a diferença entre a potência mecânica de aceleração e a potência elétrica de desaceleração é negativa. A Figura 6 mostra um caso em que o critério das áreas iguais classifica o sistema

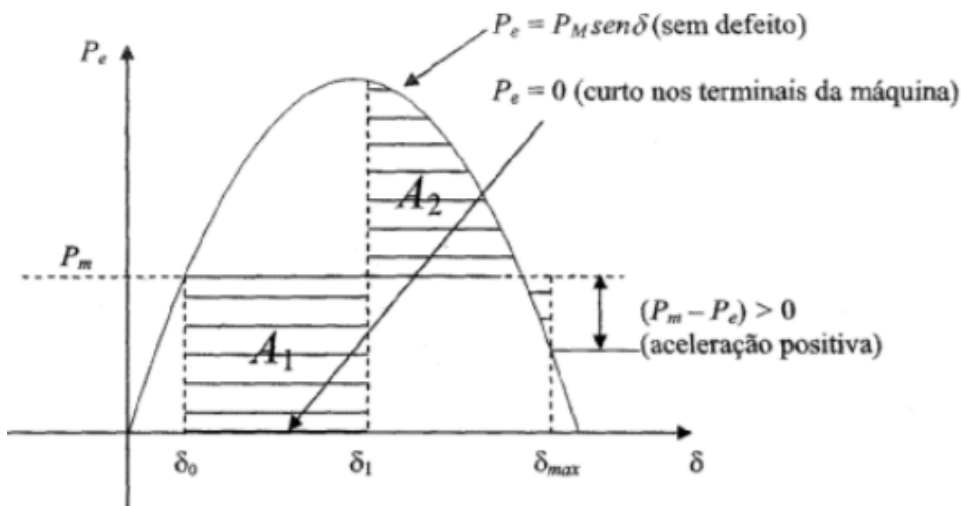
como instável, pois agora a área de aceleração  $A_1$  é maior que a área de desaceleração  $A_2$ . Neste caso, a diferença entre a potência mecânica de aceleração e a potência elétrica de desaceleração é maior que zero em  $\delta_{max}$ , fazendo com que o sistema não tenha força suficiente para permanecer estável (SILVA, 2010).

Figura 5 – Critério das áreas iguais para sistema estável



Fonte: adaptado de (SILVA, 2010).

Figura 6 – Critério das áreas iguais para sistema instável



Fonte: adaptado de (SILVA, 2010).

Os métodos matemáticos, assim como os métodos energéticos podem trazer com eles incertezas na resolução do problema de estabilidade transitória à medida que a complexidade do sistema estudado aumenta. Outro empecilho destes métodos é a grande carga computacional e tempo necessário para a solução das equações. Mesmo os computadores mais modernos não conseguem processar esse conjunto de equações de forma rápida (na ordem de milissegundos) para um sistema de grande dimensão (Hashiesh et al., 2012).

Portanto, apesar de fornecer informações importantes para o planejamento da operação, esses métodos podem não ser completamente adequados para monitorar em tempo real a estabilidade transitória da rede.

Para avaliação em tempo real, uma solução alternativa consiste em calcular o índice de estabilidade transitória a partir de sinais medidos. Essa alternativa tem se tornado muito atrativa na atualidade, pois com o auxílio das PMUs é possível obter uma ampla quantidade de dados do sistema de diversas localizações e em um curto período. Desta forma, com o auxílio dos índices de estabilidade e PMUs, técnicas de aprendizado de máquina têm sido amplamente aplicadas na previsão da estabilidade transitória em sistemas elétricos de potência.

Os índices de estabilidade transitória podem auxiliar na previsão e quantificação da capacidade do sistema em manter sua estabilidade transitória. Nessa categoria de indicadores, pode-se ressaltar o índice de energia transitória cinética (TKE), energia potencial transitória (TPE) (SAJADI; PREECE; MILANOVIĆ, 2020) e de estabilidade transitória baseado na diferença angular do rotor (TSI) (YU et al., 2018).

No índice TKE, calcula-se a energia cinética transitória do sistema logo após a falta. Para isso, a seguinte equação é utilizada:

$$TKE = \sum_{i=1}^n \frac{J_i \Delta\omega_i^2}{2} \quad (9)$$

em que  $J_i$  é o momento angular do  $i$ -ésimo gerador e  $\Delta\omega_i$  é a variação da velocidade angular do mesmo.

O TPE é o índice que leva em consideração a energia potencial transitória dos geradores logo após a eliminação da falta, a qual é calculado a partir da potência ativa injetada pelos geradores, conforme a expressão:

$$TPE = \int_{t_{falta}}^{t_{eliminação}} [\Delta P_{G_i} - \Delta P_{G_j}] \Delta f_{ij} dt \quad (10)$$

em que  $\Delta P_{G_i}$  e  $\Delta P_{G_j}$  são a potência ativa de um par de geradores  $i$  e  $j$ ,  $\Delta f_{ij}$  é a diferença de frequência entre esses geradores.  $t_{falta}$  e  $t_{eliminação}$  são os tempos em que se inicia a falta e se elimina a mesma.

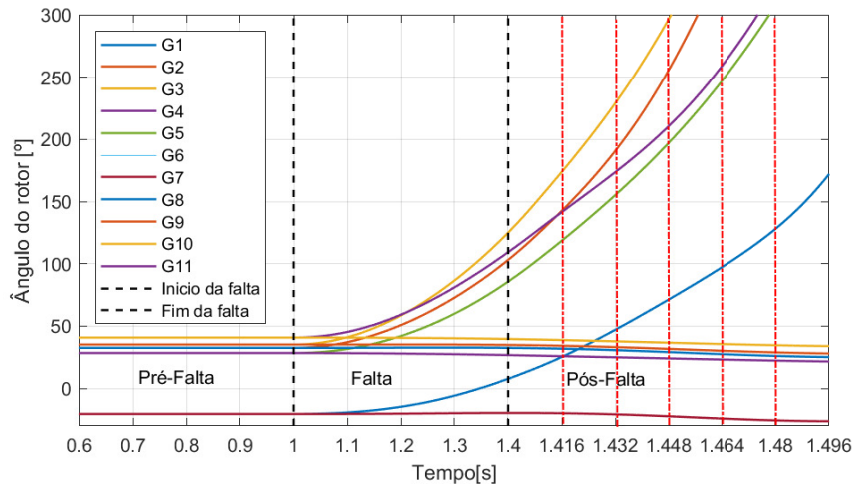
O índice mais utilizado é o índice de Estabilidade Transitória (do inglês, *Transient Stability Index* - TSI) e pode ser observado na equação (11). Este índice considera a separação máxima do ângulo do rotor entre quaisquer dois geradores do sistema após a eliminação da falta, em que a diferença angular entre os geradores é representada pelo  $\delta_{max}$ . Quanto mais próximo da unidade for o valor do índice, maior a probabilidade do sistema ser estável. Em alguns trabalhos, para o monitoramento em tempo real, estabelece-se um valor mínimo para o TSI, acima do qual o sistema é considerado estável (YU et al., 2018).

$$TSI = \frac{360 - \delta_{max}}{360 + \delta_{max}} \times 100 \quad (11)$$

Quando  $TSI > 0$ , o sistema é estável, caso contrário, o sistema é instável. Em outros termos, se  $\delta_{max} > 360$ , o sistema é considerado instável. Para determinar o valor de  $\delta_{max}$  é necessário identificar a maior diferença angular do rotor entre quaisquer dois geradores do sistema imediatamente após a eliminação da perturbação. Desse modo, o tamanho da janela de amostragem referente ao ângulo do rotor de cada gerador do sistema em estudo, após a eliminação da perturbação, é importante para determinação da variável  $\delta_{max}$  e, conseqüentemente, do índice TSI.

De modo a evidenciar esta situação, a Figura 7 demonstra a variação angular de geradores após serem submetidos a uma falta trifásica com duração de 0,4 segundos. É possível observar a separação angular entre os geradores ciclo após ciclo de medição (os ciclos são representados pelas linhas vermelhas), note que a medida em que os ciclos aumentam, a variação angular entre os geradores também aumenta, ficando evidente o comportamento instável do sistema. Desta forma, na literatura correlata, normalmente o cálculo do índice TSI é realizado a partir da 8ª amostra das variáveis no período pós-falta, ou seja oitavo ciclo.

Figura 7 – Resposta transitória do ângulo do rotor dos geradores síncronos em um SEP.



Fonte: Autoria Própria

Apesar do índice oferecer uma métrica confiável, o mesmo é dependente de um dado de difícil medição: o ângulo do rotor. Isso faz com que sua aplicação direta para a predição de estabilidade seja mais difícil. Porém, quando utilizado em conjunto com técnicas de aprendizado de máquina, esse índice torna-se de grande aplicabilidade, por exemplo, ele é de grande ajuda para a criação de bancos de dados, os quais são necessários para o treinamento de técnicas de aprendizado de máquina.



O próximo capítulo visa demonstrar alguns trabalhos desenvolvidos até os dias de hoje. Os trabalhos apresentados discutem e aplicam o aprendizado de máquinas para a previsão da estabilidade transitória de um sistema elétrico de potência.



## Capítulo 3

---

# Revisão Bibliográfica

---

Ao longo dos últimos anos, o aprimoramento e desenvolvimento de grandes áreas de monitoramento (do inglês, *Wide-Area Monitoring System* - WAMS), tem tornado possível o uso de dados monitorados para prever e mitigar problemas relacionados à estabilidade e à operação segura de um SEP. Neste contexto, pesquisas que utilizam técnicas de aprendizagem de máquina para mapear ou prever o comportamento da rede a partir de dados amostrados têm sido amplamente incentivadas.

Com intuito de identificar a evolução das pesquisas na área de estabilidade e as contribuições advindas com o uso de dados amostrados e técnicas de aprendizagem de máquina, neste capítulo, é apresentada uma revisão bibliográfica dos principais trabalhos realizados na área. Inicialmente, destacam-se as pesquisas que utilizam dados amostrados para avaliar a estabilidade angular do rotor a grandes perturbações. Em sequência, os avanços obtidos utilizando redes neurais artificiais para a previsão da estabilidade transitória são evidenciados.

### 3.1 Técnicas de Aprendizagem de Máquina aplicadas no estudo da Estabilidade Transitória

No estudo da estabilidade transitória de um sistema de potência, técnicas de aprendizagem de máquina têm sido empregadas para avaliar o comportamento dos geradores síncronos conectados na rede elétrica em análise durante os primeiros segundos de resposta da rede após a ocorrência de uma grande perturbação, analisando a variação angular dos rotores existentes. A partir de um conjunto de dados pré-definidos de forma *offline*, tais técnicas são treinadas para mapear a relação entre os parâmetros do sistema e as condições de estabilidade correspondentes. Uma vez que esta relação seja estabelecida, cada novo cenário de operação pode ser avaliado com mínimo esforço computacional, tornando assim possível uma análise *online*.

A eficácia da técnica está vinculada a qualidade e quantidade de dados utilizados para

treinamento e teste. A partir do estabelecimento de um banco de dados que reflita o comportamento dinâmico da rede em estudo após uma contingência, uma alta acurácia pode ser alcançada (Yu et al., 2018; REN C., 2018).

Neste contexto, soluções baseadas em árvores de decisão, RNAs e SVM têm sido utilizadas para mapear ou prever o comportamento da rede a partir de dados amostrados (GURUSINGHE; RAJAPAKSE, 2016; YU et al., 2018; da Cunha; FERNANDES; FERNANDES, 2022).

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. Avalia-se a capacidade da técnica em realizar essa classificação para três tipos de sinais de entrada: magnitude da tensão, desvio angular e velocidade angular do rotor. 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, a qual atinge 98% quando o preditor tem como vetor de entrada os 4 primeiros ciclos de medição da magnitude da tensão nas barras de geração.

No trabalho realizado por Li et al. (2014), duas árvores de decisão são utilizadas para prever a estabilidade transitória. A primeira árvore de decisão é utilizada para identificar o melhor posicionamento das PMUs no sistema, um diferencial deste trabalho. Na sequência, uma segunda árvore de decisão é utilizada para prever estabilidade transitória com base em trajetórias de impedância aparente, obtidas com auxílio de variáveis medidas por PMUs após 12 ciclos de eliminação da falta, essas variáveis são configuradas como entradas para árvores de decisão do tipo CART. Para averiguar o desempenho das árvores, dois sistemas testes são utilizados, o primeiro possui 123 máquinas e 162 barras e o segundo é um modelo de 29 máquinas e 128 barras do sistema *Western Electricity Coordinating Council* (WECC). Para o primeiro sistema teste a precisão atingida pela DT foi de 95%. No segundo sistema teste a precisão atingida pela DT foi de 95,44% demonstrando um ótimo desempenho.

Outro trabalho que faz o uso de árvores de decisão para a previsão da estabilidade transitória é desenvolvido em (GUO; MILANOVIC, 2014). Neste estudo, para construir o banco de dados uma distribuição uniforme discreta do tempo de eliminação da falta, variando de 0,05s a 0,29s com um incremento de 0,02s é aplicada para todas as linhas que compõe a rede. Os ângulos e as velocidades do rotor do gerador são selecionados como preditores, ou seja, dados de entrada. A partir de testes realizados no sistema IEEE 68 barras, a eficácia do método é avaliado de acordo com a severidade da falta. Para faltas mais leves, a árvore possui uma previsão de 100% para os casos estáveis. No entanto para falta severas (que levem o sistema à instabilidade para diferentes cenários de perturbação), a acurácia atinge um patamar de apenas 90%, quando a predição é realizada com dados medidos imediatamente após a eliminação da perturbação. Se um vetor de

entrada composto por 48 ciclos de medição (considerando um ciclo com duração de 1/60 s) de cada atributo é fornecido ao método, um índice de 98% de acurácia é alcançado mesmo nos cenários de instabilidade.

A previsão da estabilidade transitória também é realizada a partir de um método baseado na técnica de máquina de aprendizado extremo (do inglês, *extreme learning machine* - ELM) (ZHANG TIE LI; LI, 2015). Neste trabalho o sistema utilizado para os testes de predição possui 39 barras. O tipo de falta utilizada para as simulações do sistema teste foram curtos-circuitos trifásicos, e os tempos de eliminação da falta variam de cinco a dez ciclos. As saídas de potência ativa e reativa de cada gerador são correspondentemente atribuídas como entrada para o treinamento do algoritmo, o que é um ponto positivo, uma vez que esses dados são fornecidos diretamente pelas PMUs. Neste trabalho, para melhorar o desempenho da previsão do ELM, o modelo ideal é obtido aplicando o algoritmo de otimização de enxame de partículas aprimorado IPSO (do inglês, *improved particle swarm optimization algorithm* - IPSO). O modelo foi comparado a outros dois métodos de otimização, o algoritmo de otimização por enxame de partículas (do inglês, *particle swarm optimization* - PSO) e o algoritmo genético (do inglês, *genetic algorithm* - GA). Os resultados obtidos foram de 97,50% para o IPSO, 95,24% para o GA e 94,20% para o PSO. Além disto o tempo de treinamento do ELM-IPSO foi cerca de 10 segundos mais rápido que os demais. O método também foi comparado a outras técnicas de aprendizado de máquinas como DT, SVM e MLP. Os resultados do ELM foram superiores atingindo 97,50% enquanto as outras técnicas não ultrapassaram 96% de acurácia.

Árvores de decisão e uma variação da técnica SVM para múltiplas classes (do inglês, *Multiclass Support Vector Machine* - MSVM) são aplicadas por (GUO; 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.

## 3.2 Avaliação da Estabilidade Transitória a partir de Redes Neurais

Com a grande disponibilidade de dados sobre o sistema elétrico de potência, as técnicas de redes neurais artificiais ganham espaço na análise da estabilidade transitória, assim como as demais técnicas mencionadas na seção anterior.

No início dos anos 2000, os autores Bahbah e Girgis (2004) utilizaram dois tipos de RNAs, a *perceptron* de multicamadas e as redes neurais recorrentes (do inglês, *recurrent neural networks* - RNN) para avaliar a estabilidade transitória de um sistema elétrico

de potência. Diferente dos trabalhos atuais o sistema teste utilizado possui apenas 3 geradores e 9 barras. Durante os testes os autores mostram que as RNAs do tipo MLP apresentaram dificuldade de convergência mesmo quando o número de entradas utilizado para a predição aumenta. Por outro lado, as redes neurais RNN demonstraram alta taxa de acurácia. A utilização de dados para a predição que não são fornecidos diretamente pelas PMUs, como variação dos ângulos e velocidades angulares dos geradores ao longo do tempo, é uma desvantagem desta metodologia.

Outra pesquisa com RNAs é feita pelo autores Sawhney e Jeyasurya (2006), o qual baseia-se em uma MLP que recebe como dados para a predição, a potência do gerador, o ângulo do rotor do gerador, o fluxo de potência ativa e reativa da linha de transmissão e a potência consumida pelas cargas das barras do sistema em estudo após 8 ciclos da eliminação de uma perturbação, uma grande quantidade de dados quando comparado com métodos atuais. Esses dados foram selecionados com o auxílio de técnicas de seleção de recursos a fim de reduzir a quantidade de dados necessários para a predição. Para averiguar a estabilidade do sistema foi utilizado um índice de estabilidade baseado no critério das áreas iguais. Os resultados são observados por meio de uma análise gráfica do comportamento do sistema frente a dois casos de perturbação, no sistema IEEE 39 barras.

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.

Já em Ardeshiri Lajimi e Amraee (2016) uma RNA é aplicada para avaliar o tempo crítico de abertura, ou seja, o tempo máximo para que uma determinada perturbação seja removida do sistema sem que resulte na instabilidade do mesmo. Neste trabalho, uma estrutura de dois estágios é criada para garantir o fluxo de potência ótimo com restrição na estabilidade transitória, o primeiro estágio consiste na utilização de RNAs para calcular o tempo crítico de abertura *Critical Clearing Time (CCT)*. A rede utilizada é uma MLP alimentada por valores de potência e tensão nas barras. Para avaliar o desempenho da RNA é usado o erro quadrático médio normalizado, e o resultado foi de 0,00058. O segundo estágio consiste em utilizar a técnica de algoritmo competitivo imperialista (ICA) (do inglês, *Imperialist Competitive Algorithm* - ICA) para encontrar a solução ótima de um problema de otimização.

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

grupo 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 (ZHOU et al., 2019; SHI et al., 2020; STIASNY; MISYRIS; CHATZIVASILEIADIS, 2021).

Por exemplo, a pesquisa proposta por Zhou et al. (2019) apresenta uma abordagem sistemática para construir e atualizar um classificador de estabilidade transitória. Os dados de entrada para o treinamento da CNN, são o ângulo e tensão nos barramentos já a quantidade de ciclos utilizada para a medição das variáveis ocorre em um intervalo de 6 a 12 ciclos. A saída da RNA informa o estado de estabilidade do sistema, ou seja, se ele é estável ou instável. Foram treinados 3 classificadores CNN com arquiteturas diferentes e uma média entre os mesmos foi considerada como resultado. Para avaliar a eficácia da técnica, os testes foram realizados em dois sistemas testes: o sistema IEEE 39 barras, e o sistema *Northeast Power Coordinating Council* (NPCC), o qual é composto por 48 geradores síncronos e 140 barras. Os resultados para o primeiro sistema teste obteve uma precisão de 98,63% com dados de 9 ciclos. Para o segundo sistema teste a precisão atingida foi de 98,77% também com dados de 9 ciclos de medição.

Já o trabalho desenvolvido 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 também por um método baseado em uma rede neural convolucional. 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 IEEE 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  $\theta$  correspondem à magnitude e ângulo da tensão na barra, enquanto  $\delta$  refere-se ao ângulo do rotor de um dado gerador. Nota-se que a acurácia atingida nos trabalhos elencados é alta, acima de 98% em alguns trabalhos. Além disso, verifica-se que o sistema 39 barras e 68 barras são amplamente utilizados para verificar a eficiência dos métodos desenvolvidos. Com relação à quantidade mínima de ciclos consecutivos de medição necessários, observa-se que uma alta precisão é alcançada quando apenas 4 ciclos são utilizados para a classificação da estabilidade em (GOMEZ et al., 2011). 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
Li et al. (2014)	DT	$Z=X+Ji$	12	97,4%	162
Guo e Milanovic (2014)	DT	$\delta$	10	98,0%	68
Zhang Tie Li e Li (2015)	ELM	PV e PQ	10	97,5%	39
Guo e Milanovi (2016)	SVM	$\delta$	10	98,0%	68
Ardeshiri Lajimi e Amraee (2016)	RNA	P e V	–	–	–
Siddiqui et al. (2018)	RNA	V e $\delta$	6	–	39
Yu et al. (2018)	LSTM	V	8	99,0%	39
Zhou et al. (2019)	CNN	V	9	98,7%	140
Shi et al. (2020)	CNN	V	15	98,1%	179

### 3.3 Análise Geral

Os trabalhos acima mostram alguns estudos realizados para avaliação do sistema de potência e sua segurança, mais específico na área de estabilidade transitória. Os mesmos apresentam características em comum, por exemplo, a base do banco de dados gerado para treinamento e testes das técnicas empregadas, possuem grande variedade de perturbações. Isso ocorre para que a capacidade de generalização dos algoritmos empregados seja maior.



Além disso, a grande maioria relatam a quantidade de ciclos utilizados no pós-falta para a medição de suas variáveis de entrada.

Apesar dos métodos de aprendizado de máquina demonstrarem uma alta acurácia na classificação, existem pesquisas que utilizam de medições, que dificilmente, estão disponíveis ou até mesmo indiquem boa precisão no ambiente prático, como o ângulo do rotor, velocidade angular da máquina ou potência mecânica. Neste sentido é interessante que se explore o uso das medições feitas pelas PMUs como alguns trabalhos propõem. Com o auxílio da PMU possui-se alta disponibilidade de informações em tempo real, o que dentre outras características podem propor métodos que são facilmente aplicados para a análise da estabilidade transitória.

Nos trabalhos apresentados as medições de variáveis utilizadas para a previsão do classificador em grande maioria são realizadas a partir do oitavo ciclo após a eliminação da falta. Dito isto um ponto pouco explorado é a análise de precisão a partir de medições com baixo número de ciclos após a eliminação da falta, durante avaliações de segurança em tempo real. Nesse cenário, esse trabalho propõe, especificamente, para a análise de estabilidade transitória, um método centralizado baseado em redes neurais que investiga quantidade mínima de ciclos de medição necessárias. Nesse método, será explorado o potencial de um classificador que utiliza apenas as medições de barras geradoras, para identificar casos de instabilidade. As medições são fasores de tensão nas barras, medidas estas sendo fornecidas diretamente pelas PMUs.

A escolha das Redes Neurais como algoritmo de aprendizagem de máquina, como ressaltado nos trabalhos revisados, reside na simplicidade de implementação, baixo custo computacional e grande precisão, que pode auxiliar na tomada de decisão por parte do operador. É importante destacar, também, que a baixa complexidade do algoritmo implica na necessidade de menos amostras para o treinamento.



## Capítulo 4

---

# Método Proposto para Predição da Estabilidade Transitória

---

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 investigou-se a utilização de redes neurais artificiais para identificar o comportamento transitório de uma rede no período pós-falta, de modo a prever situações de instabilidade, possibilitando assim que o operador do sistema tome as providências necessárias para manter o SEP estável.

Para o desenvolvimento do trabalho, inicialmente, é necessário criar o banco de dados, contendo o comportamento transitório da rede a diferentes tipos de perturbação aplicadas. Em sequência, é realizado o treinamento da RNA. Após o modelo de predição ser estabelecido, a técnica deve ser capaz de prever a instabilidade transitória ou a estabilidade do sistema a partir do novo conjunto de dados medidos, contendo a magnitude e o ângulo da tensão nas barras selecionadas.

Esse capítulo inicia-se apresentando aspectos fundamentais da técnica para classificação utilizada, as redes neurais artificiais. Em sequência, as etapas necessárias para o desenvolvimento do preditor de estabilidade transitória proposto são descritas.

### 4.1 Redes Neurais Artificiais

As RNAs, também conhecidas como sistemas de processamento paralelo distribuído, são modelos computacionais inspirados no funcionamento do cérebro de seres vivos, mais específico o cérebro humano. Isso porque o cérebro humano possui uma maneira de calcular totalmente diferente dos computadores, pois tem uma capacidade ímpar em organizar os seus neurônios para realização de um cálculo (BRAGA; CARVALHO; LUDERMIR, 2010).

O surgimento das RNAs começa em 1943 com os pesquisadores Warren McCulloch e Walter Pitts, responsáveis por desenvolver o primeiro modelo artificial de um neurônio biológico, os chamados nodos (KOVACS, 1996). O trabalho deles teve como foco descrever o modelo de neurônio artificial computacional, sem aprofundar ou descrever o treinamento desse modelo. Em 1949, um primeiro método de treinamento foi proposto por Donald Hebb, cuja regra de aprendizado consiste na variação dos pesos de entrada dos nodos, a qual ficou conhecida como regra de aprendizado de Hebb (BRAGA CARVALHO, 2007).

Posteriormente, vieram Frank Rosenblatt (1958) com seu modelo perceptron, Widrow e Hoff (1960) com as redes Adaline, Madaline e a Adaline múltipla. No entanto, em 1969, Minsky e Papert demonstraram as limitações existentes em redes neurais de apenas uma camada, como as redes perceptron e adaline (BRAGA CARVALHO, 2007). Somente na década de 80, devido ao melhoramento tecnológico, as RNAs voltaram a ter relevância, com destaque em 1986 com a publicação do livro de Rumelhart sobre redes com múltiplas camadas (KOVACS, 1996). Desde então, as RNAs têm sido amplamente aplicadas para solução de problemas em diferentes áreas.

As RNAs possuem diversas aplicações como aproximadores universais de funções, controle de processos, reconhecimento e classificação de padrões, agrupamento de dados, sistemas de previsão e otimização de sistemas, além de memórias associativas (KOVACS, 1996). Elas permitem a aproximação de diversas funções independentemente da resposta do sistema em análise ser linear ou não linear. Estas características tornam a utilização de RNAs bastante atrativa, uma vez que depois de passar pela etapa de aprendizado, ela pode generalizar a informação aprendida e fornecer respostas precisas por meio de dados não conhecidos (BRAGA; CARVALHO; LUDERMIR, 2010). Comumente, as redes neurais são treinadas para que uma entrada específica leve a uma saída de destino específica. Portanto, a rede é ajustada com base na comparação da saída real e da saída desejada até que a saída desejada, seja igual ou muito próxima da saída real. Para isso, muitos desses pares de entrada/saída são necessários para treinar uma rede.


Um neurônio artificial é apresentado pela Figura 8, em que é possível identificar as variáveis envolvidas na unidade elementar. Ele é composto por um vetor de entrada  $x = [x_1, x_2, \dots, x_n]$ , (representando os dendritos) e um terminal de saída único  $y$  (representando o axônio). Pesos sinápticos  $w = [w_1, w_2, \dots, w_n]$  ponderam as informações do comportamento do sistema mapeado (ou seja, do vetor de entrada). Em seguida, à soma ponderada de todas as entradas pelos pesos sinápticos adiciona-se um limiar de ativação  $\theta$ . O valor resultante é repassado como argumento da função de ativação,  $g()$ . Matematicamente, um neurônio artificial pode ser representado da seguinte forma (SILVA IVAN NUNES DA; SPATTI, 2010):

$$u = \sum_{i=1}^m w_i x_i \quad (12)$$

$$y = g(u + \theta) \quad (13)$$


em que  $y$  é a saída,  $g$  é uma função de ativação,  $m$  é o número de entradas,  $x_i$  é a  $i$ -ésima entrada,  $w_i$  é o peso associado a  $i$ -ésima entrada e, por fim,  $\theta$  refere-se ao limiar ativação do neurônio.

Figura 8 – Neurônio Artificial



Fonte: Autoria Própria.

Figura 9 – Arquitetura simples de uma RNA



Fonte: (SILVA IVAN NUNES DA; SPATTI, 2010).

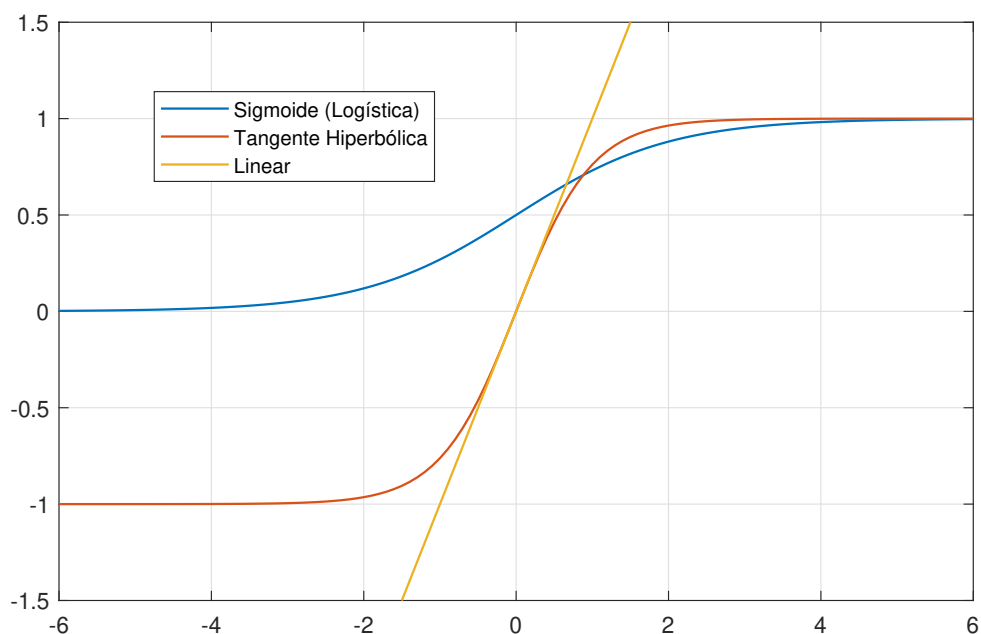
Uma rede neural, como mostra a Figura 9, é composta por diversos neurônios artificiais, os quais podem estar dispostos em diversas camadas. Os neurônios que recebem diretamente as entradas da rede constituem o que se chama de camada de entrada. O vetor das variáveis de entrada  $x = [x_1, x_2, x_3, \dots, x_n]$  são também denominados como atributos ou *features*. O vetor de pesos sinápticos  $w = [w_1, w_2, w_3, \dots, w_n]$ , são responsáveis pela simulação dos comportamentos sinápticos e ponderam as variáveis de entrada da rede neural, definindo a importância de cada uma. Tais pesos podem assumir valores positivos

ou negativos, cujo valor quantifica o acoplamento sináptico entre um neurônio emissor e um neurônio receptor.

Quando o peso  $w$  da sinapse é positivo, o neurônio é excitado e quando negativo é inibido. O limiar de ativação cria um potencial de ativação relacionando aos sinais de entrada e seus respectivos pesos atribuídos. Já o potencial de ativação  $u$  é o resultado produzido entre o combinador linear e o limiar de ativação. Se seu valor for maior que o limiar de ativação possui característica excitatória, caso contrário o potencial será inibitório.

As funções de ativação por sua vez possuem características diferentes umas das outras, como mostra a Figura 10, cada uma será utilizada para o tipo de problema a ser solucionado ou até mesmo ao tipo de arquitetura a ser utilizada por uma RNA. Por exemplo uma função de ativação sigmoide é comumente utilizada por redes neurais que precisam ter como saída apenas números positivos. Por outro lado uma função de ativação do tipo tangente, é utilizada para redes neurais que necessitam de saídas entre -1 e 1. Por fim, uma função linear pode assumir valores de  $-\infty$  a  $\infty$ . Elas fazem com que a saída do neurônio tenha um intervalo de valores razoáveis que serão assumidos pela sua própria imagem funcional. Finalmente, o sinal de saída ( $y$ ), é o valor final produzido pelo neurônio baseado em um conjunto de dados de entrada (SILVA IVAN NUNES DA; SPATTI, 2010).

Figura 10 – Funções de ativação




Fonte: Autoria Própria.

### 4.1.1 *Perceptron* Multicamadas

Essa arquitetura de RNA tem como característica ter pelo menos uma camada intermediária que é conhecida como a camada escondida ou camada oculta de neurônios, ela está presente entre a camada de entrada e a camada de saída como mostra a Figura 11. A passagem por essas camadas escondidas consiste em extrair a maior parte das informações referentes ao problema em questão, e assim codificá-los por meio dos pesos sinápticos e limiares de seu neurônio. O número de camadas escondidas, assim como a quantidade de neurônios a serem utilizados na topologia da RNA, depende de diversos fatores do sistema.

Figura 11 – Arquitetura simples de uma RNA



Fonte: (SILVA IVAN NUNES DA; SPATTI, 2010).

As redes perceptron multicamadas (do inglês, *multilayer perceptron* - MLP) pertencem à arquitetura *feedforward* de camadas múltiplas cujo treinamento é feito de forma supervisionada. Esta arquitetura mostra que as entradas passam de camada para camada, ou seja, a saída da primeira camada escondida será a entrada da próxima camada, isso acontece continuamente até a camada de saída. Assim a propagação de sinais, independentemente do número de camadas, ocorre apenas em uma direção, diferente de outras arquiteturas (BRAGA CARVALHO, 2007).

O processo de treinamento é dividido basicamente em duas etapas. A etapa *forward* (propagação adiante), aqui os sinais de entrada ( $x_1, x_2, x_3, \dots, x_n$ ) são propagados de camada para camada até a camada de saída, sem alteração de seus pesos sinápticos ou limiares de seus neurônios. Em sequência, as respostas fornecidas pela camada de saída são comparadas às respostas desejadas já existentes, para que o erro seja calculado e, posteriormente, os pesos sinápticos e limiares de todos os neurônios sejam ajustados.

A segunda etapa é a etapa de *backpropagation* que seria a (propagação reversa), tem como objetivo fazer com que os pesos sinápticos e limiares dos neurônios sejam ajustados mediante o cálculo dos erros realizado na primeira etapa, assim com a sucessiva aplicação das duas fases os pesos sinápticos e limiares dos neurônios se ajustam automaticamente

em cada iteração, diminuindo cada vez mais o erro produzido através das camadas (SILVA IVAN NUNES DA; SPATTI, 2010).

Existem diferentes arquiteturas de redes neurais, como as redes recorrentes RNNs. As RNNs tomam não apenas um exemplo de entrada atual, mas também o que percebem anteriormente no tempo. Isso porque as saídas de uma camada neural podem ser realimentadas nas camadas de entrada. Para a tomada de decisão de uma RNN leva-se em conta a etapa do tempo anterior que afeta a tomada de decisão do momento presente. Com isso as RNNs possuem duas fontes de entrada, o presente e o passado recente, ambas se combinam para determinar como respondem a novos dados. Porém, a implementação de redes neurais recorrentes requer um maior esforço computacional assim como complexidade de aplicação, quando comparadas com as redes neurais *feedforward*.

Neste trabalho as redes neurais a serem utilizadas são redes neurais simples, como a *perceptron* multicamadas, uma vez que permitem atingir uma alta acurácia no problema abordado, além do baixo custo computacional e complexidade de aplicação. Tais características beneficiam principalmente o método no que se refere à velocidade da predição.

## 4.2 Abordagem proposta para predição da estabilidade transitória

Na abordagem desenvolvida nesse trabalho, apenas as medidas realizadas nas barras de geração do sistema em estudo são necessárias. O classificador proposto deve ser capaz de identificar se a resposta do sistema pós-falta é estável ou instável, a partir dos primeiros ciclos de medição da resposta do sistema no período pós-falta. Os dados de entrada do modelo de predição são as séries históricas das variáveis de magnitude e ângulo de tensão das barras de interesse no período pós-falta.

Uma vez treinado, o modelo de predição a base de rede neural não requer um alto esforço computacional para classificação, o que torna possível sua aplicação em tempo real. Após classificar o sistema como estável ou instável, as informações são enviadas ao operador do sistema e conseqüentemente, este pode avaliar a estabilidade do mesmo e tomar as ações necessárias para uma operação segura da rede.

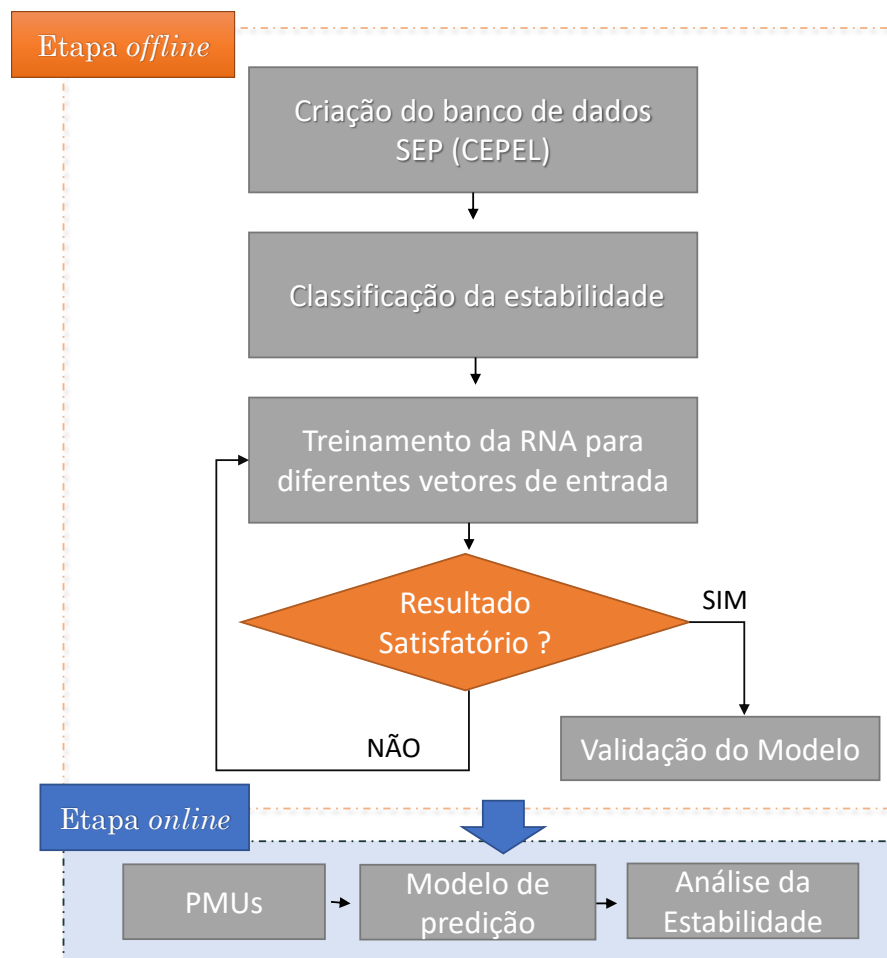
Um ponto importante a ser investigado na metodologia proposta é com relação à redução da dimensionalidade do vetor de entrada da rede neural. Se um vetor de entrada de menor dimensão é necessário para o modelo de predição, é possível reduzir a sua complexidade, resultando em um menor tempo de processamento e na redução da quantidade de amostras para formação do banco de dados na etapa de treinamento. Essa análise é um diferencial dessa proposta, dado que ela permite identificar a quantidade mínima de ciclos necessários pelo modelo de predição, tornando possível estabelecer uma melhor relação entre a velocidade da estimativa e a acurácia. 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.

A Figura 12 apresenta o diagrama de blocos que descreve o método proposto, desde a criação do banco, a partir da implementação do sistema teste nos programas do Centro de Pesquisa em Engenharia Elétrica (CEPEL), até os treinamentos e testes executados, no MATLAB.

Figura 12 – Diagrama da abordagem utilizada.



Fonte: Autoria própria.

#### 4.2.1 Formação do banco de dados sobre grandes perturbações diante do sistema teste

A primeira etapa do método proposto consiste na formação do banco de dados, ou seja, 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. A eficácia do modelo de predição a ser construído e do seu poder de generalização está diretamente relacionado com a qualidade desse banco de dados.

Para que o banco de dados contenha amostras de diferentes condições de operação do sistema, são considerados níveis distintos de carregamento da rede, caracterizando três patamares de carga: leve, média e pesada.

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 nas linhas disponíveis do sistema teste em análise. E exclui-se as linhas que provocam o ilhamento dos geradores;
2. **O Tempo de duração da falta** - são testados de forma determinística. É comum que a variação aconteça no intervalo de 200 a 700 ms, com discretização de 50 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 compatível com a de uma PMU. Os fasores da magnitude e ângulo da tensão nas barras serão monitorados e armazenados com ajuda do *software* MATLAB em planilhas do EXCEL. Nestas simulações que acontecem de forma *offline*, os ângulos dos rotores também são armazenados para obtenção do índice TSI. A organização dos dados é feita de forma que facilite posteriormente a sua utilização para o treinamento das RNAs. Dito isto, os dados são salvos em planilhas separadas, cada planilha consta com os fasores de tensão das barras de geração com séries históricas composta por 8 ciclos de medição.

Para a definição do *status* de estabilidade da rede para cada amostra, utiliza-se o índice de estabilidade transitória baseado em diferença angular do rotor - TSI, já apresentado no capítulo 2. Esse índice avalia a diferença máxima entre quaisquer dois geradores após a remoção da falta, representado pela variável  $\delta_{max}$ , a equação é apresentada novamente para facilitar o acompanhamento:

$$TSI = \frac{360 - \delta_{max}}{360 + \delta_{max}} \quad (14)$$

Note que a equação não define o instante de tempo em que deve ser feita a medição da variável  $\delta_{max}$ , deixando apenas claro que essa deve ocorrer no período pós-falta. Conforme a literatura correlata (SAJADI; PREECE; MILANOVIC, 2020), neste trabalho foi utilizado uma medição de 10 ciclos após a eliminação da falta para categorizar o comportamento do sistema no banco de dados. Um tutorial detalhado, contendo os procedimentos para a criação do banco de dados é exibido no Apêndice B

### 4.3 Treinamento e Validação do Classificador a base de Rede Neurais Artificiais.

Após a montagem do banco de dados, inicia-se a etapa de treinamento e validação da rede neural. Uma porcentagem de 70% dos dados do banco é utilizada para treinamento, enquanto a parcela restante é utilizada na validação. Nos bancos resultantes de treinamento e validação, inicialmente, prepara-se um *dataset* balanceado, com quantidades semelhantes de casos instáveis e casos estáveis, com objetivo reduzir 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. Os critérios de parada para o treinamento da RNA são de 1000 épocas ou quando o MSE (do inglês, *Mean Squared Error* - MSE) de  $1.0^{-07}$  é atingido. Este erro faz a comparação entre a saída da rede e a saída real.

Dito isto no treinamento, diferentes arquiteturas são avaliadas para identificar qual atinge uma maior acurácia dentro do problema avaliado. Para isso os neurônios da camada oculta são variados com discretização de 5 neurônios até atingirem o máximo de 50 neurônios. Uma vez encontrada a arquitetura ideal, ou seja, a arquitetura que demonstre a maior acurácia média, é realizado o treinamento de 50 redes 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.

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:

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

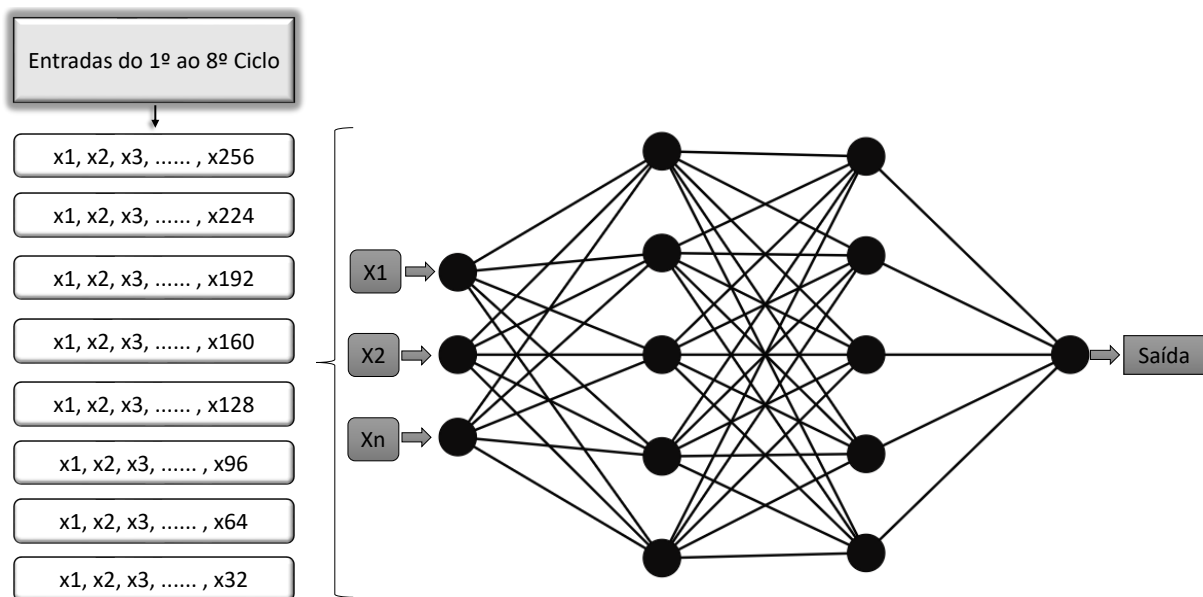
em que  $V_{B_i}$  corresponde ao valor da magnitude e do ângulo da tensão de cada  $i$ -ésima barra de geração, ou seja,  $V = V_{B_i} \angle \theta_{B_i}$ . A variável  $T$  refere-se ao instante de medição

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. Para exemplificar esse aspecto, na Figura 13, é possível verificar a dimensão de entrada do vetor de características para um sistema em que a magnitude e ângulo da tensão (2 variáveis) em 16 barras são mensurados. Os diferentes vetores de características são representados do 1º ao 8º ciclo de medição para essas duas variáveis. Para cada vetor de entrada, uma nova RNA é avaliada.

Deste modo uma maior quantidade de ciclos resulta em um maior vetor de entrada para a RNA. Por outro lado, quando um menor número de ciclos é necessário, mais simples é a arquitetura da RNA, pois reduz a dimensão do vetor de características para a entrada da mesma. Dessa forma, é possível reduzir o tempo de processamento necessário no treinamento e nas predições, o que é de grande benefício caso o desempenho do classificador não sofra. 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).

Figura 13 – Vetor de entrada para as RNAs.



Fonte: Autoria própria.

### 4.3.1 Métodos de validação

Com o objetivo de analisar o desempenho do classificador, a métrica adotada na execução deste trabalho foi a acurácia. Tal métrica é usualmente utilizada para avaliar a qualidade de um modelo de predição construído a partir de técnicas de aprendizagem de máquina.

Essa métrica utilizada é um aspecto distinto de uma matriz de confusão, a tabela 2 apresenta o exemplo de uma matriz de confusão. Nesta matriz, a coluna *atual* refere-se os valores reais da amostra, já o termo *predito* corresponde aos valores de classe preditos pelo classificador.

Tabela 2 – Matriz de Confusão

Atual	Predito	
	Positivo	Negativo
Positivo	VP	FN
Negativo	FP	VN

Os verdadeiros positivos (VP) são as amostras que pertencem à classe positiva e que foram preditas como positivas pelo classificador. Os falsos negativos (FN) são as amostras que pertencem a classe positiva, mas foram classificadas como negativas. Os falsos positivos (FP) são amostras da classe negativa que foram classificadas como positivas e os verdadeiros negativos (VN) são amostras negativas que foram preditas como negativas. Vale ressaltar, que neste trabalho a classe positiva será considerada estável e a classe negativa será atribuída aos casos instáveis. Essa configuração tem impacto direto na forma com que se aplicam as métricas propostas.

Com o objetivo de analisar o desempenho do classificador proposto, a acurácia é calculada, 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:

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + VN + FN} \quad (15)$$



## Capítulo 5

---

# Resultados

---

Para avaliar a eficácia da abordagem proposta, testes foram realizados em um sistema amplamente utilizado na literatura para estudar o comportamento dinâmico da rede no período pós-falta, o sistema IEEE 68 barras (CANIZARES et al., 2017). Inicialmente é construído um amplo banco de dados com a relação do comportamento transitório da rede para diferentes cenários de operação e perturbações. Posteriormente 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.

Os resultados obtidos bem como as características do conjunto de dados construído são descritas nas subseções que seguem.

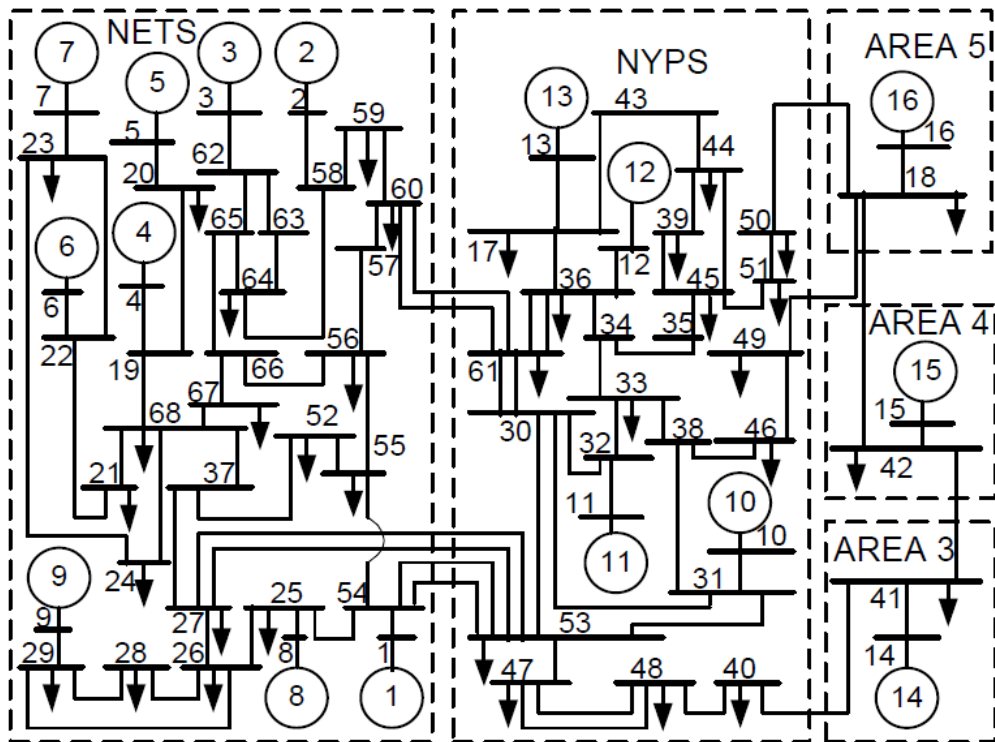
### 5.1 Sistema Teste

O sistema IEEE 68 barras corresponde ao exibido na Figura 14, 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.

Existem três modos inter-áreas presentes no sistema, e todos eles têm uma alta participação dos estados mecânicos dos geradores G14, G15 e G16. O desafio deste sistema

Figura 14 – Diagrama unifilar do sistema IEEE 68 Barras.



Fonte: (CANIZARES et al., 2017).

reside na dificuldade de amortecer seus modos locais inter-áreas contando apenas com PSSs, considerando que três de suas maiores máquinas são equivalentes do sistema e não usinas reais. No caso base, o sistema possui três modos interáreas com razão de amortecimento menor que 10%, que estão descritos na Tabela 3. O modo 1 requer mais atenção por ser o modo menos amortecido do sistema, apresentando um fator de amortecimento de 2,38%, caracterizando a oscilação da área 5 (gerador 16) contra a área 4 (gerador 15) e 3 (gerador 14). Portanto, para essa condição de operação, o sistema é classificado como mal amortecido, apesar de ser estável.

Tabela 3 – Modos eletromecânicos do sistema de teste

Modos	$\sigma \pm j\omega$	Freq. (Hz)	$\zeta(\%)$
1	$-0,079 \pm j3,331$	0,5302	2,380
2	$-0,145 \pm j4,901$	0,7800	2,956
3	$-0,335 \pm j3,680$	0,5857	9,076

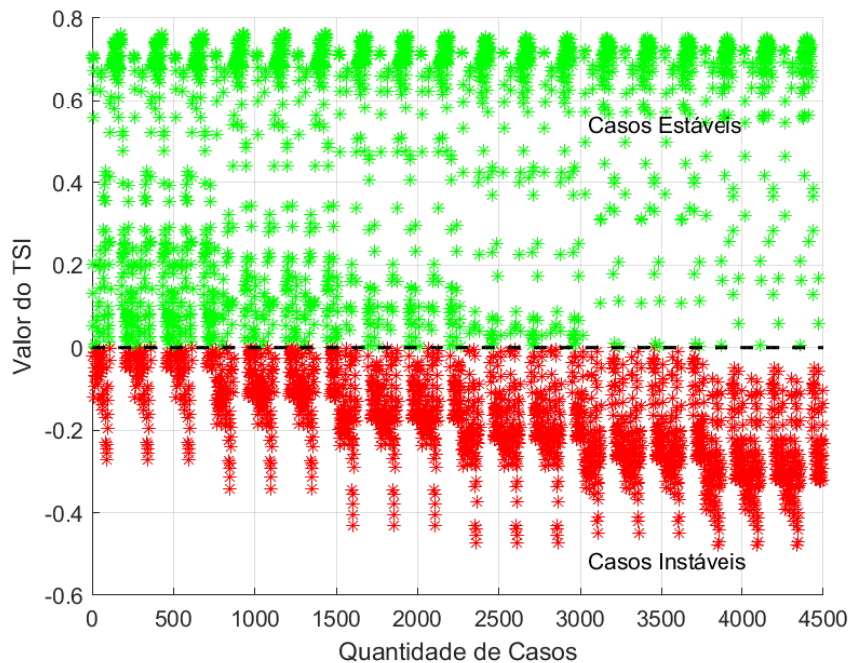


## 5.2 Banco de dados do sistema teste de 68 Barras

A partir das combinações relatadas, para a criação do banco de dados, curtos-circuitos foram aplicados em todas as linhas do sistema teste, excluindo as linhas que provocam o ilhamento dos geradores, a porcentagem do comprimento de linha onde a falta é aplicada vai de 20% a 80%. A duração do curto-circuito varia de 0,35 segundos a 0,65 segundos. As faltas são aplicadas em três situações de carregamento do sistema, carga nominal, carga mínima e carga máxima. A carga mínima opera com 17% abaixo da carga nominal do SEP e a carga máxima opera com 17% acima da carga nominal do SEP. Esses valores foram definidos com ajuda do *software* ANAREDE, verificando qual foi o maior e menor nível de carregamento do sistema, sem que o mesmo atingisse a instabilidade. Em seguida foi construído um banco de dados composto por 5292 casos, em que cada caso é classificado como estável ou instável a partir do cálculo do índice TSI. O valor do TSI identificado em cada caso é exibido na Figura 15.


Note a existência de cenários com valores de TSI bem próximos a fronteira entre os casos estáveis e instáveis. Esses casos podem ser visualizados com maior proximidade na Figura 16, demonstrando que nenhum deles está sobre a linha de fronteira, o que garante maior confiabilidade da classificação dos sistemas em estáveis e instáveis utilizando o cálculo do índice TSI. Ademais, observe que o banco resultante é desbalanceado com uma maior quantidade de casos estáveis do que instáveis.

Figura 15 – Resultado do índice TSI.



Fonte: Autoria Própria.

Figura 16 – Resultado do índice TSI sobre a região de fronteira.



Fonte: Autoria Própria.

Deste modo, para o treinamento das RNAs, 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 que nos 2093 casos restantes o sistema apresenta um comportamento dinâmico instável. Esse procedimento contribui para um melhor aprendizado das RNAs, deste modo foi de grande ajuda no trabalho realizado.

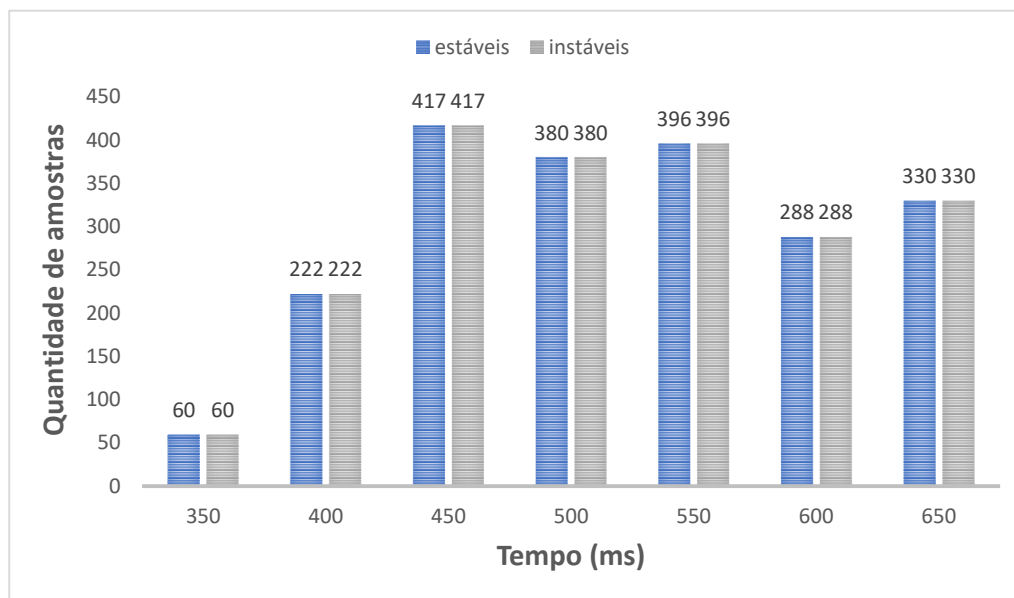
O balanceamento dos cenários estáveis e instáveis foi realizado com o tempo de duração da falta conforme exibido na Figura 17. Note que as faltas trifásicas com duração de 350 ms e 400 ms resultam em um menor número de cenários instáveis e, portanto, um menor número de instâncias foi gerada para faltas 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.

### 5.3 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-se de acordo com a dimensão do vetor de entrada, ou seja, mediante ao número de 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 4

Figura 17 – Relação dos casos estáveis e instáveis por tempo de duração da falta trifásica aplicada.



Fonte: Autoria própria.

exibe a quantidade de atributos que formam o vetor de entrada para cada RNA avaliada.

Tabela 4 – 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

Com o objetivo de encontrar a melhor arquitetura para as RNAs, 64 redes foram testadas para cada ciclo, variando 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. Esta segunda camada inicia com a 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 a média dos resultados, reduzindo o impacto da aleatoriedade dos valores dos pesos sinápticos na acurácia obtida pelo preditor avaliado.

Com intuito de ilustrar esse procedimento, a acurácia média atingida para cada RNA com uma camada escondida é apresentada na Tabela 5, quando 8 ciclos de cada medição são consideradas no vetor de entrada. Já na Tabela 6 é possível acompanhar esse índice, quando varia-se a quantidade de neurônios em duas camadas escondidas. A arquitetura que resulta na maior acurácia nessas tabelas está destacada em negrito.

Tabela 5 – Teste de arquitetura das RNAs 8 ciclos com 1 camada.

RNA	Neurônios 1 <sup>o</sup> Camada	Acurácia Média das 10 RNAs (%)
1 <sup>o</sup>	5	77,72
2 <sup>o</sup>	10	89,21
3 <sup>o</sup>	15	93,93
4 <sup>o</sup>	20	95,03
5 <sup>o</sup>	25	95,61
6 <sup>o</sup>	30	93,73
7 <sup>o</sup>	35	96,63
8 <sup>o</sup>	40	97,21
<b>9<sup>o</sup></b>	<b>45</b>	<b>97,43</b>
10 <sup>o</sup>	50	97,13

Note que, pela Tabela 5, uma RNA de apenas 1 camada com 45 neurônios obtém uma acurácia média de 97,43%, muito próxima a acurácia atingida por uma RNA de duas camadas (com 20 neurônios na primeira camada e 25 neurônios na segunda), cuja acurácia é de 97,60%. Levando este ponto em consideração, o desvio padrão entre as 10 RNAs treinadas com apenas uma camada e o desvio padrão das 10 RNAs treinadas com 2 camadas foram calculados. De posse do desvio padrão é possível encontrar a arquitetura que fornece maior uniformidade nos treinamentos e, portanto, esse critério foi utilizado para definição da arquitetura.

Na Tabela 7 é possível identificar o desvio padrão associada a essas duas arquiteturas, portanto, a RNA composta por duas camadas (com 20 neurônios na primeira camada e 25 neurônios na segunda), é adotada para representar a rede de 8 ciclos. O mesmo procedimento é aplicado para a definição da arquitetura para cada grupo de ciclos de medição, cujas tabelas podem ser vistas no Apêndice A.

Dentre as 64 redes treinadas para cada grupos de ciclos, a Tabela 8 apresenta a quantidade de neurônios presentes em cada camada escondida da arquitetura que atingiu a maior valor médio da acurácia. Note que independente da quantidade de ciclos no vetor de entrada, 20 ou 25 neurônios na 1<sup>a</sup> camada já são suficientes para classificação nas arquiteturas avaliadas.

Tabela 6 – Teste de arquitetura das RNAs 8 ciclos com 2 camadas.

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	5	96,66
2º	5	10	94,71
3º	5	15	92,55
4º	5	20	94,31
5º	5	25	95,59
6º	5	30	94,82
7º	5	35	91,00
8º	5	40	94,33
9º	5	45	89,99
10º	5	50	93,00
20º	10	10	96,72
11º	10	15	96,82
12º	10	20	97,09
13º	10	25	97,44
14º	10	30	95,76
15º	10	35	96,41
16º	10	40	96,67
17º	10	45	96,50
18º	10	50	96,16
19º	15	15	97,34
20º	15	20	96,76
21º	15	25	97,04
22º	15	30	96,89
23º	15	35	96,77
24º	15	40	96,63
25º	15	45	96,81
26º	15	50	97,08
27º	20	20	96,87
<b>28º</b>	<b>20</b>	<b>25</b>	<b>97,60</b>
29º	20	30	97,08
30º	20	35	97,24
31º	20	40	97,03
32º	20	45	97,27
33º	20	50	97,03
34º	25	25	97,17
35º	25	30	97,04
36º	25	35	97,31
37º	25	40	97,09
38º	25	45	97,11
39º	25	50	97,28
40º	30	30	97,29
41º	30	35	96,84
42º	30	40	97,19
43º	30	45	97,36
44º	30	50	97,61
45º	35	35	97,10
46º	35	40	97,06
47º	35	45	97,31
48º	35	50	97,38
49º	40	40	97,45
50º	40	45	97,50
51º	40	50	97,22
52º	45	45	96,53
53º	45	50	97,15
54º	50	50	97,13

Tabela 7 – Desvio padrão das RNAs de 1 e 2 camadas para a RNA de 8 ciclos.

<b>Rede</b>	<b>1º Camada</b>	<b>2º Camada</b>	<b>Desvio Padrão</b>	<b>Acurácia Média</b>
8 Ciclos	45	-	0,72	97,43%
8 Ciclos	20	25	0,40	97,60%

A Tabela 8 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 %), no entanto, essa diferença é de apenas 1,33%.

Tabela 8 – Quantidade de neurônios por camada.

<b>Redes</b>	<b>1º Camada</b>	<b>2º Camada</b>	<b>Acurácia Média</b>
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%

### 5.3.1 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. Com esse objetivo, 50 RNAs foram treinadas para cada configuração exibida na Tabela 8. Esse procedimento permite identificar a eficácia média das arquiteturas escolhidas e garante que os resultados aqui apresentados não sofram com o impacto de aleatoriedade, uma vez que uma grande quantidade de RNAs é testada. A acurácia média e o desvio padrão atingidos para cada rede é exibido na Tabela 9.

Tabela 9 – 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 9, 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 1,38% entre o valor máximo e mínimo de acurácia média. Todas as redes avaliadas atingem uma acurácia máxima acima de 98%, sendo que o valor mais alto é atingido pela RNA de 5 ciclos (99,05%). O desvio padrão apresentado na Tabela 5, 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 para cada um dos 8 modelos de predição foi investigada a partir do *boxplot* detalhado na Figura 18. 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%, independentemente 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 do SEP. No entanto, há uma pequena redução no patamar da acurácia resultante do modelo, quando comparadas as RNAs treinadas para 5, 6 e 7 ciclos, isso ocorre por que a distribuição dos valores de acurácia obtidos para tais ciclos, são menores. 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.

### 5.3.2 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

Figura 18 – Boxplot do resultado das 50 RNAs avaliadas para cada modelo de predição.



Fonte: Autoria própria.

sera 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 janela de dados maior for 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, independentemente do grau de severidade da falta, a acurácia atingida foi acima de 96%, evidenciando a eficácia da abordagem proposta em classificar a estabilidade da rede a partir do fasor de tensão das barras de geração, medidas estas que são fornecidas diretamente por meio das PMUs.

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 IEEE 39 barras. 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). Outro fato a ser mencionado é o sistema teste utilizado, que neste trabalho possui 68 Barras e 16 geradores, o que caracteriza um maior vetor de entrada para as RNAs, fato este que trás mais complexidade para a predição.

Uma característica importante deste trabalho é a utilização da acurácia média, a qual não é relatada pelos outros trabalhos, deste modo assume-se que os trabalhos citados



na Tabela 1 demonstram a acurácia máxima obtida pela técnica de predição utilizada. Deste modo o método aqui proposto possui uma acurácia máxima a ser comparada com a Tabela 1 de 98,89% para uma RNA que utiliza para a predição apenas 4 ciclos de medição após a eliminação de uma perturbação.

Portanto, a partir de uma técnica relativamente simples, uma RNA do tipo perceptron de múltiplas camadas, a abordagem proposta atinge uma acurácia muito próxima à técnicas mais sofisticadas tal como uma CNN utilizada por 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.



## Capítulo 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 localizadas 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 com ajuda dos *softwares* ANAREDE, ANATEM e MATLAB, 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 desenvolvidos, resultando em uma acurácia média superior a 97,85% quando se utiliza pelo 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, houve 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

---

ALBERTO, L. F. C.; BRETAS, N. G. **Estabilidade transitória em sistemas eletroenergéticos**. São Carlos, Brasil: EESC-USP, 2000.

Ardeshiri Lajimi, R.; AMRAEE, T. A two stage model for rotor angle transient stability constrained optimal power flow. **International Journal of Electrical Power Energy Systems**, v. 76, p. 82–89, 2016. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061515003427>>.

ARIFF, M. A. M.; PAL, B. C.; SINGH, A. K. Estimating dynamic model parameters for adaptive protection and control in power system. **IEEE Transactions on Power Systems**, v. 30, n. 2, p. 829–839, March 2015. ISSN 0885-8950.

AYAR, M. et al. A distributed control approach for enhancing smart grid transient stability and resilience. **IEEE Transactions on Smart Grid**, v. 8, n. 6, p. 3035–3044, 2017.

BAHBAH, A.; GIRGIS, A. New method for generators' angles and angular velocities prediction for transient stability assessment of multimachine power systems using recurrent artificial neural network. **IEEE Transactions on Power Systems**, v. 19, n. 2, p. 1015–1022, 2004.

Balu, N. et al. On-line power system security analysis. **Proceedings of the IEEE**, v. 80, n. 2, p. 262–282, 1992.

BRAGA, A. de P.; CARVALHO, A. P. de L. F.; LUDERMIR, T. B. Redes neurais artificiais: Teoria e aplicações. **Rio de Janeiro: Ltc, 2007. 262 p**, v. 2, 2010.

BRAGA CARVALHO, L. Redes neurais artificiais - teoria e aplicações. **Collegium Cognito**, v. 2, n. ISBN-10 8521615647, p. 248, 2007.

BRETAS, N. G.; ALBERTO, L. F. C. **Estabilidade transitória em sistemas eletroenergéticos**. [S.l.]: EESC/USP, 2000.

CANIZARES, C. et al. Benchmark models for the analysis and control of small-signal oscillatory dynamics in power systems. **IEEE Transactions on Power Systems**, v. 32, n. 1, p. 715–722, Jan 2017. ISSN 0885-8950.

da Cunha, G. L.; FERNANDES, R. A.; FERNANDES, T. C. C. Small-signal stability analysis in smart grids: An approach based on distributed decision trees. **Electric Power Systems Research**, v. 203, p. 107651, 2022.

GERON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. United States: O'reilly., 2017.

GOMEZ-EXPOSITO, A.; CONEJO, A. J.; CANIZARES, C. **Sistemas de Energia Elétrica: Análise e Operação**. 1. ed. Rio de Janeiro: LTC, 2011. 572 p. ISBN 978-85-216-1802-7.

GOMEZ, F. R. et al. Support vector machine-based algorithm for post-fault transient stability status prediction using synchronized measurements. **IEEE Transactions on Power Systems**, v. 26, n. 3, p. 1474–1483, 2011.

GUO, T.; MILANOVI, J. V. Online identification of power system dynamic signature using pmu measurements and data mining. **IEEE Transactions on Power Systems**, v. 31, p. 1760–1768, Maio 2016.

GUO, T.; MILANOVIC, J. V. Probabilistic framework for assessing the accuracy of data mining tool for online prediction of transient stability. **IEEE Transactions on Power Systems**, v. 29, n. 1, p. 377–385, 2014.

Guo, T.; Milanović, J. V. Online identification of power system dynamic signature using pmu measurements and data mining. **IEEE Transactions on Power Systems**, v. 31, n. 3, p. 1760–1768, 2016.

GURUSINGHE, D. R.; RAJAPAKSE, A. D. Post-disturbance transient stability status prediction using synchrophasor measurements. **IEEE Transactions on Power Systems**, v. 31, n. 5, p. 3656–3664, 2016.

HASHIESH, F. et al. A wide area synchrophasor based ann transient stability predictor for the egyptian power system. In: **2010 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT Europe)**. [S.l.: s.n.], 2010. p. 1–7.

Hashiesh, F. et al. An intelligent wide area synchrophasor based system for predicting and mitigating transient instabilities. **IEEE Transactions on Smart Grid**, v. 3, n. 2, p. 645–652, 2012.

Hiskens, I. A.; Hill, D. J. Energy functions, transient stability and voltage behaviour in power systems with nonlinear loads. **IEEE Transactions on Power Systems**, v. 4, n. 4, p. 1525–1533, 1989.

KOVACS, Z. L. **Redes neurais artificiais: Fundamentos e aplicações um texto básico**. LTC, São Paulo, n. 9788586396021, 1996.

KUNDUR, P. **Power System Stability and Control**. [S.l.]: McGraw-Hill, 1994.

Kundur, P. et al. Definition and classification of power system stability ieeecigre joint task force on stability terms and definitions. **IEEE Transactions on Power Systems**, v. 19, n. 3, p. 1387–1401, 2004.

KUNDUR, P. et al. Definition and classification of power system stability ieeecigre joint task force on stability terms and definitions. **Power Systems, IEEE Transactions on**, v. 19, n. 3, p. 1387 – 1401, aug. 2004. ISSN 0885-8950.

- LI, M. et al. Transient stability prediction based on apparent impedance trajectory recorded by pmus. **International Journal of Electrical Power Energy Systems**, v. 54, p. 498–504, 2014. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061513003207>>.
- LIU, C. et al. A systematic approach for dynamic security assessment and the corresponding preventive control scheme based on decision trees. **IEEE Transactions on Power Systems**, v. 29, n. 2, p. 717–730, 2014.
- MIHAILESCU, R.-C.; OSSOWSKI, S.; KLUSCH, M. Ecoop: Applying dynamic coalition formation to the power regulation problem in smart grids. **Computational Intelligence**, v. 33, n. 3, p. 401–427, 2017. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/coin.12093>>.
- Morison, K.; Lei Wang; Kundur, P. Power system security assessment. **IEEE Power and Energy Magazine**, v. 2, n. 5, p. 30–39, 2004.
- NOHARA, A. A.; ASSIS, T. M. L.; VALENTINI, T. M. Avaliação da estabilidade transitória de sistemas de energia elétrica através de um sistema neuro-fuzzy. **XLI SBPO - Rio de Janeiro**, p. 37–48, 2009.
- Phadke, A. G. et al. The wide world of wide-area measurement. **IEEE Power and Energy Magazine**, v. 6, n. 5, p. 52–65, 2008.
- REN C., X. Y. . Z. Y. Post-disturbance transient stability assessment of power systems towards optimal accuracy-speed tradeoff. **Prot Control Mod Power Syst** 3, v. 19, n. 3, 2018.
- SAJADI, A.; PREECE, R.; MILANOVIC, J. **Evaluation of Suitability of Different Transient Stability Indices for Identification of Critical System States**. 2020.
- SAJADI, A.; PREECE, R.; MILANOVIĆ, J. V. Evaluation of Suitability of Different Transient Stability Indices for Identification of Critical System States. **arXiv**, 2020.
- SAWHNEY, H.; JEYASURYA, B. A feed-forward artificial neural network with enhanced feature selection for power system transient stability assessment. **Electric Power Systems Research**, v. 76, n. 12, p. 1047–1054, 2006. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779606000034>>.
- SHI, Z. et al. Convolutional neural network-based power system transient stability assessment and instability mode prediction. **Applied Energy**, v. 263, p. 114586, 2020. ISSN 0306-2619. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306261920300982>>.
- SIDDIQUI, S. A. et al. Real-time monitoring of post-fault scenario for determining generator coherency and transient stability through ann. **IEEE Transactions on Industry Applications**, v. 54, n. 1, p. 685–692, 2018.
- SILVA IVAN NUNES DA; SPATTI, D. H. F. R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. [S.l.: s.n.], 2010.
- SILVA, J. L. e. **Análise da Estabilidade Transitória Utilizando o software PS-Lab**. 2010. 74 p.

SILVA, L. M. G. L. G. L. P. M. D. **ESTUDO DE ESTABILIDADE TRANSITÓRIA EM SISTEMAS MULTIMÁQUINAS**. 2013. 85 p.

SONI, B. P. et al. Identification of generator criticality and transient instability by supervising real-time rotor angle trajectories employing rbfnn. **ISA Transactions**, v. 83, p. 66–88, 2018. ISSN 0019-0578. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0019057818303082>>.

STIASNY, J.; MISYRIS, G. S.; CHATZIVASILEIADIS, S. **Transient Stability Analysis with Physics-Informed Neural Networks**. [S.l.]: arXiv, 2021.

TAN, B. et al. Representational learning approach for power system transient stability assessment based on convolutional neural network. **The Journal of Engineering**, v. 2017, n. 13, p. 1847–1850, 2017. Disponível em: <<https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/joe.2017.0651>>.

THEODORO, E. A. R. **Contribuição à análise de estabilidade transitória, em duas escalas de tempo, de sistemas elétricos de potência via métodos diretos**. Tese (Tese (Doutorado em Sistemas Elétricos de Potência)) — Universidade de São Paulo -USP, São Carlos, SP, 2017.

VITTAL, A.-A. F. e V. Power system transient stability analysis using the transient energy function method. **Englewood Cliffs NJ, USA: Prentice-Hall.**, 1992.

YU, J. J. et al. Intelligent time-adaptive transient stability assessment system. **IEEE Transactions on Power Systems**, IEEE, v. 33, n. 1, p. 1049–1058, 2018. ISSN 08858950.

Yu, J. J. Q. et al. Intelligent time-adaptive transient stability assessment system. **IEEE Transactions on Power Systems**, v. 33, n. 1, p. 1049–1058, 2018.

YU, J. J. Q. et al. Intelligent time-adaptive transient stability assessment system. **IEEE Transactions on Power Systems**, v. 33, n. 1, p. 1049–1058, 2018.

Yusof, S. B.; Rogers, G. J.; Alden, R. T. H. Slow coherency based network partitioning including load buses. **IEEE Transactions on Power Systems**, v. 8, n. 3, p. 1375–1382, 1993.

ZHANG, J. et al. Instantaneous electromechanical dynamics monitoring in smart transmission grid. **IEEE Transactions on Industrial Informatics**, v. 12, n. 2, p. 844–852, 2016.

ZHANG TIE LI, G. N. G. L. Y.; LI, Y. Optimized extreme learning machine for power system transient stability prediction using synchrophasors. **Mathematical Problems in Engineering**, 2015. Disponível em: <<http://dx-doi.ez31.periodicos.capes.gov.br>>.

ZHOU, Y. et al. A novel data-driven approach for transient stability prediction of power systems considering the operational variability. **International Journal of Electrical Power Energy Systems**, v. 107, p. 379–394, 2019. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061518319914>>.



# Apêndices



## APÊNDICE A

---

# Definição da Arquitetura das Redes Neurais para cada Vetor de Entrada

---

A fim de encontrar a arquitetura ideal para RNAs que possuem como vetor de entrada 7, 6, 5, 4, 3, 2 e 1 ciclos. As Tabelas 10, 11, 12, 13, 14, 15 e 16, demonstram o resultado do procedimento proposto para tal. Todas as tabelas possuem 64 arquiteturas diferentes, cada uma destas arquiteturas é treinada 10 vezes e então a acurácia média obtida por elas é relatada. Um total de 7 Tabelas são apresentadas, uma para cada vetor característico, contendo os dados de tensão e ângulo nas barras geradoras do sistema teste. Cada Tabela corresponde a um vetor de entrada diferente, que começa com 7 ciclos na Tabela 10 e termina com apenas 1 ciclo na 16.

A Tabela 17 mostra o desvio padrão obtido pelas arquiteturas de maior acurácia média quando são utilizados para predição 8, 7, 6 e 5 ciclos. O desvio padrão das RNAs de 4, 3, 2 e 1 ciclos não foi calculado, pois de acordo com as tabelas 13, 14, 15 e 16 do apêndice A a acurácia média atingida pelas arquiteturas de 1 camada estão muito distante das obtidas por 2 camadas.

Tabela 10 – Teste de arquitetura das RNAs 7 ciclos

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	-	88,72
2º	10	-	90,19
3º	15	-	95,58
4º	20	-	97,36
5º	25	-	97,46
6º	30	-	97,03
7º	35	-	97,79
8º	40	-	96,65
9º	45	-	96,96
10º	50	-	96,68
11º	5	5	93,93
12º	5	10	94,48
13º	5	15	95,12
14º	5	20	94,13
15º	5	25	95,02
16º	5	30	94,90
17º	5	35	95,48
18º	5	40	96,12
19º	5	45	93,05
20º	5	50	95,45
20º	10	10	96,96
21º	10	15	95,89
22º	10	20	95,70
23º	10	25	96,97
24º	10	30	97,39
25º	10	35	97,08
26º	10	40	96,28
27º	10	45	97,01
28º	10	50	97,11
29º	15	15	96,84
30º	15	20	97,54
31º	15	25	97,49
32º	15	30	96,93
33º	15	35	97,40
34º	15	40	97,37
35º	15	45	96,92
36º	15	50	97,38
37º	20	20	97,36
38º	20	25	97,22
39º	20	30	97,52
40º	20	35	97,54
41º	20	40	97,74
42º	20	45	97,05
43º	20	50	97,19
44º	25	25	97,04
45º	25	30	97,51
46º	25	35	97,57
47º	25	40	97,75
<b>48º</b>	<b>25</b>	<b>45</b>	<b>97,80</b>
49º	25	50	97,62
50º	30	30	97,37
51º	30	35	97,34
52º	30	40	97,38
53º	30	45	97,13
54º	30	50	97,44
55º	35	35	97,69
56º	35	40	97,47
57º	35	45	97,60
58º	35	50	97,36
59º	40	40	97,63
60º	40	45	97,58
61º	40	50	97,72
62º	45	45	97,16
63º	45	50	97,50
64º	50	50	96,69

Tabela 11 – Teste de arquitetura das RNAs 6 ciclos

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	-	85,19
2º	10	-	95,29
3º	15	-	97,04
4º	20	-	96,55
5º	25	-	96,07
6º	30	-	96,38
7º	35	-	97,69
8º	40	-	96,65
9º	45	-	95,91
10º	50	-	96,47
11º	5	5	92,68
12º	5	10	95,56
13º	5	15	94,12
14º	5	20	91,04
15º	5	25	95,77
16º	5	30	94,21
17º	5	35	94,63
18º	5	40	95,88
19º	5	45	94,55
20º	5	50	90,12
20º	10	10	96,75
21º	10	15	92,19
22º	10	20	96,76
23º	10	25	96,60
24º	10	30	94,86
25º	10	35	96,89
26º	10	40	97,13
27º	10	45	96,71
28º	10	50	94,36
29º	15	15	95,60
30º	15	20	96,65
31º	15	25	97,62
32º	15	30	97,17
33º	15	35	97,42
34º	15	40	97,26
35º	15	45	97,23
36º	15	50	97,43
37º	20	20	96,87
38º	20	25	97,60
39º	20	30	97,08
40º	20	35	97,24
41º	20	40	97,03
42º	20	45	97,27
43º	20	50	97,43
44º	25	25	97,65
45º	25	30	97,50
<b>46º</b>	<b>25</b>	<b>35</b>	<b>97,85</b>
47º	25	40	97,23
48º	25	45	97,62
49º	25	50	97,28
50º	30	30	97,48
51º	30	35	96,57
52º	30	40	97,25
53º	30	45	94,94
54º	30	50	97,03
55º	35	35	96,99
56º	35	40	95,76
57º	35	45	97,62
58º	35	50	97,50
59º	40	40	97,41
60º	40	45	97,44
61º	40	50	97,19
62º	45	45	97,22
63º	45	50	97,54
64º	50	50	97,51

Tabela 12 – Teste de arquitetura das RNAs 5 ciclos

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	-	91,75
2º	10	-	91,73
3º	15	-	95,95
4º	20	-	94,23
5º	25	-	96,98
6º	30	-	96,05
7º	35	-	96,10
8º	40	-	94,90
9º	45	-	97,09
10º	50	-	96,02
11º	5	5	95,72
12º	5	10	94,21
13º	5	15	95,13
14º	5	20	95,13
15º	5	25	95,38
16º	5	30	94,21
17º	5	35	95,45
18º	5	40	94,11
19º	5	45	94,63
20º	5	50	95,87
20º	10	10	96,26
21º	10	15	96,30
22º	10	20	96,62
23º	10	25	96,00
24º	10	30	95,99
25º	10	35	96,41
26º	10	40	93,48
27º	10	45	95,75
28º	10	50	95,12
29º	15	15	95,60
30º	15	20	96,65
31º	15	25	97,60
32º	15	30	97,07
33º	15	35	97,38
34º	15	40	97,18
35º	15	45	97,20
36º	15	50	97,58
37º	20	20	96,96
38º	20	25	96,91
39º	20	30	96,85
40º	20	35	94,90
41º	20	40	97,30
42º	20	45	96,40
43º	20	50	96,92
44º	25	25	97,49
45º	25	30	96,42
46º	25	35	96,75
47º	25	40	96,51
48º	25	45	97,19
<b>49º</b>	<b>25</b>	<b>50</b>	<b>97,85</b>
50º	30	30	97,80
51º	30	35	96,49
52º	30	40	97,01
53º	30	45	96,83
54º	30	50	97,00
55º	35	35	97,23
56º	35	40	96,53
57º	35	45	97,19
58º	35	50	96,98
59º	40	40	96,68
60º	40	45	97,05
61º	40	50	96,37
62º	45	45	96,75
63º	45	50	94,37
64º	50	50	97,10

Tabela 13 – Teste de arquitetura das RNAs 4 ciclos

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	-	87,16
2º	10	-	94,97
3º	15	-	92,47
4º	20	-	95,43
5º	25	-	95,47
6º	30	-	93,24
7º	35	-	95,17
8º	40	-	93,20
9º	45	-	95,62
10º	50	-	95,91
11º	5	5	96,82
12º	5	10	93,91
13º	5	15	95,67
14º	5	20	95,73
15º	5	25	95,48
16º	5	30	94,91
17º	5	35	96,35
18º	5	40	94,91
19º	5	45	95,93
20º	5	50	96,89
20º	10	10	95,43
21º	10	15	95,02
22º	10	20	95,71
23º	10	25	96,60
24º	10	30	95,90
25º	10	35	95,96
26º	10	40	96,17
27º	10	45	91,15
28º	10	50	95,65
29º	15	15	95,94
30º	15	20	95,83
31º	15	25	96,98
32º	15	30	96,69
33º	15	35	96,81
34º	15	40	94,11
35º	15	45	96,95
36º	15	50	96,75
<b>37º</b>	<b>20</b>	<b>20</b>	<b>97,74</b>
38º	20	25	97,58
39º	20	30	96,82
40º	20	35	97,11
41º	20	40	96,38
42º	20	45	96,61
43º	20	50	96,58
44º	25	25	96,80
45º	25	30	97,00
46º	25	35	97,38
47º	25	40	97,42
48º	25	45	97,25
49º	25	50	97,15
50º	30	30	97,19
51º	30	35	96,75
52º	30	40	97,05
53º	30	45	97,21
54º	30	50	96,64
55º	35	35	96,90
56º	35	40	97,43
57º	35	45	96,55
58º	35	50	97,52
59º	40	40	96,57
60º	40	45	96,98
61º	40	50	97,18
62º	45	45	97,17
63º	45	50	96,88
64º	50	50	97,28

Tabela 14 – Teste de arquitetura das RNAs 3 ciclos

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	-	89,08
2º	10	-	91,04
3º	15	-	94,55
4º	20	-	93,66
5º	25	-	94,00
6º	30	-	94,44
7º	35	-	94,70
8º	40	-	96,55
9º	45	-	94,28
10º	50	-	95,24
11º	5	5	93,97
12º	5	10	93,78
13º	5	15	94,14
14º	5	20	91,78
15º	5	25	93,28
16º	5	30	95,03
17º	5	35	93,14
18º	5	40	95,37
19º	5	45	94,50
20º	5	50	94,01
20º	10	10	94,98
21º	10	15	95,52
22º	10	20	95,14
23º	10	25	96,91
24º	10	30	96,07
25º	10	35	95,45
26º	10	40	94,28
27º	10	45	95,55
28º	10	50	96,68
29º	15	15	96,77
30º	15	20	95,99
31º	15	25	96,07
32º	15	30	96,41
33º	15	35	95,15
34º	15	40	96,65
35º	15	45	95,16
36º	15	50	95,85
37º	20	20	96,65
38º	20	25	96,13
39º	20	30	96,10
40º	20	35	95,54
<b>41º</b>	<b>20</b>	<b>40</b>	<b>96,91</b>
42º	20	45	95,62
43º	20	50	96,17
44º	25	25	95,92
45º	25	30	96,38
46º	25	35	96,53
47º	25	40	95,99
48º	25	45	95,88
49º	25	50	96,07
50º	30	30	95,53
51º	30	35	96,38
52º	30	40	96,77
53º	30	45	96,68
54º	30	50	95,53
55º	35	35	95,85
56º	35	40	95,94
57º	35	45	96,15
58º	35	50	96,21
59º	40	40	96,76
60º	40	45	96,45
61º	40	50	96,17
62º	45	45	96,89
63º	45	50	96,91
64º	50	50	96,90



Tabela 15 – Teste de arquitetura das RNAs 2 ciclos

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	-	88,07
2º	10	-	92,04
3º	15	-	93,57
4º	20	-	93,67
5º	25	-	93,98
6º	30	-	94,44
7º	35	-	93,69
8º	40	-	96,44
9º	45	-	94,28
10º	50	-	95,28
11º	5	5	93,96
12º	5	10	93,78
13º	5	15	94,14
14º	5	20	91,71
15º	5	25	93,28
16º	5	30	95,03
17º	5	35	93,13
18º	5	40	95,36
19º	5	45	94,59
20º	5	50	94,01
20º	10	10	94,09
21º	10	15	95,52
22º	10	20	95,14
23º	10	25	96,15
24º	10	30	96,08
25º	10	35	95,46
26º	10	40	94,30
27º	10	45	95,57
28º	10	50	96,08
29º	15	15	96,17
30º	15	20	95,98
31º	15	25	96,08
32º	15	30	96,43
33º	15	35	95,15
34º	15	40	96,13
35º	15	45	95,16
36º	15	50	95,86
37º	20	20	96,05
38º	20	25	96,13
<b>39º</b>	<b>20</b>	<b>30</b>	<b>96,47</b>
40º	20	35	95,55
41º	20	40	96,37
42º	20	45	95,62
43º	20	50	96,18
44º	25	25	95,90
45º	25	30	96,38
46º	25	35	96,23
47º	25	40	95,99
48º	25	45	95,89
49º	25	50	96,09
50º	30	30	96,26
51º	30	35	96,38
52º	30	40	96,35
53º	30	45	96,46
54º	30	50	95,54
55º	35	35	95,85
56º	35	40	95,91
57º	35	45	96,17
58º	35	50	96,22
59º	40	40	96,21
60º	40	45	96,44
61º	40	50	96,16
62º	45	45	96,13
63º	45	50	96,25
64º	50	50	96,20

Tabela 16 – Teste de arquitetura das RNAs 1 ciclo

RNA	Neurônios 1º Camada	Neurônios 2º Camada	Acurácia Média das 10 RNAs (%)
1º	5	-	87,74
2º	10	-	87,75
3º	15	-	85,19
4º	20	-	87,29
5º	25	-	85,76
6º	30	-	87,40
7º	35	-	84,71
8º	40	-	90,67
9º	45	-	89,69
10º	50	-	86,41
11º	5	5	91,14
12º	5	10	91,35
13º	5	15	91,77
14º	5	20	91,10
15º	5	25	92,23
16º	5	30	90,77
17º	5	35	90,77
18º	5	40	92,95
19º	5	45	90,98
20º	5	50	92,03
20º	10	10	94,98
21º	10	15	95,52
22º	10	20	95,14
23º	10	25	92,23
24º	10	30	96,07
25º	10	35	95,45
26º	10	40	94,28
27º	10	45	95,55
28º	10	50	96,60
29º	15	15	96,27
30º	15	20	95,99
31º	15	25	96,07
32º	15	30	96,41
33º	15	35	95,15
34º	15	40	96,25
35º	15	45	95,65
36º	15	50	95,85
<b>37º</b>	<b>20</b>	<b>20</b>	<b>96,62</b>
38º	20	25	96,13
39º	20	30	96,10
40º	20	35	95,54
41º	20	40	96,60
42º	20	45	95,88
43º	20	50	96,17
44º	25	25	95,92
45º	25	30	96,38
46º	25	35	96,53
47º	25	40	95,99
48º	25	45	95,88
49º	25	50	96,07
50º	30	30	96,52
51º	30	35	96,38
52º	30	40	96,27
53º	30	45	96,60
54º	30	50	95,53
55º	35	35	95,85
56º	35	40	95,94
57º	35	45	96,15
58º	35	50	96,21
59º	40	40	96,24
60º	40	45	96,45
61º	40	50	96,17
62º	45	45	96,23
63º	45	50	96,25
64º	50	50	96,13

Tabela 17 – Desvio padrão das RNAs de 1 e 2 camadas.

<b>Rede</b>	<b>1º Camada</b>	<b>2º Camada</b>	<b>Desvio Padrão</b>	<b>Acurácia Média</b>
8 Ciclos	45	-	0,72	97,43%
8 Ciclos	20	25	0,40	97,60%
7 Ciclos	35	-	0,55	97,79%
7 Ciclos	25	45	0,35	97,80%
6 Ciclos	35	-	0,77	97,69%
6 Ciclos	25	35	0,56	97,85%
5 Ciclos	45	-	1,37	97,09%
5 Ciclos	25	50	0,55	97,85%

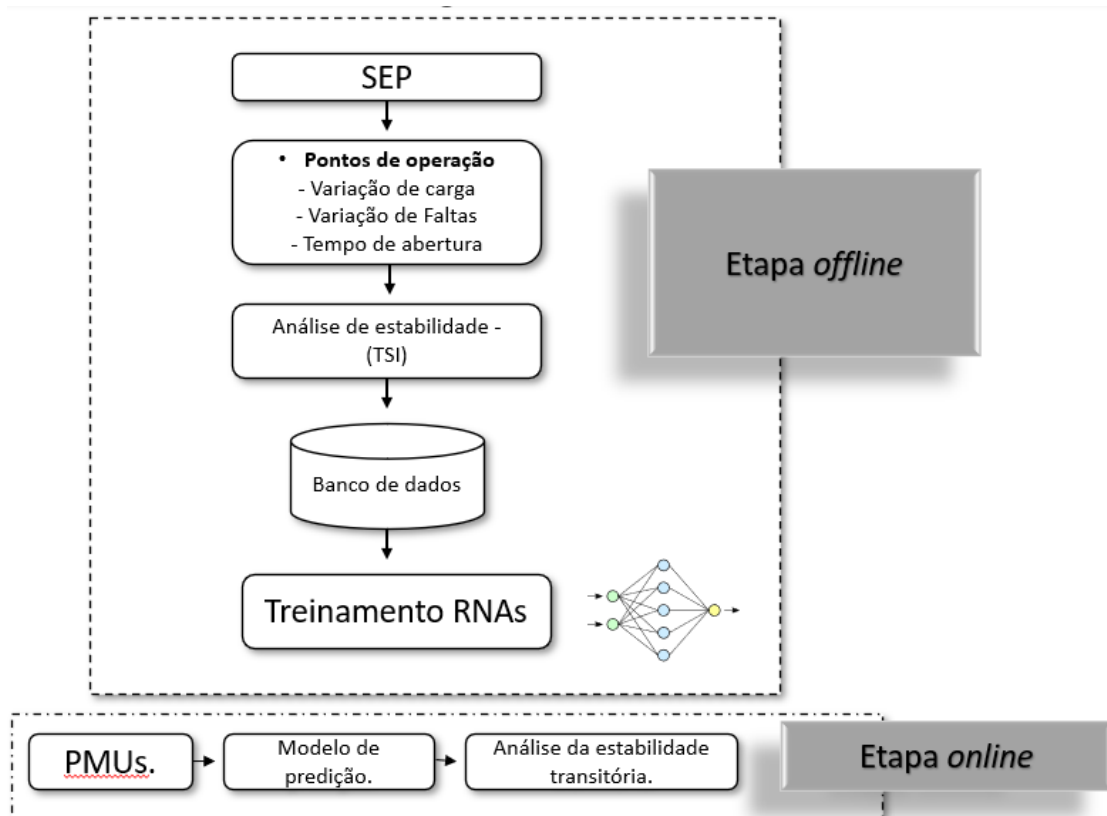


## APÊNDICE B

# Metodologia proposta

A Figura 19 demonstra todo o processo realizado pela metodologia proposta. Neste trabalho foi realizada a etapa *offline*.

Figura 19 – Metodologia



Fonte: Autoria própria.

A escolha do sistema teste leva em consideração os trabalhos realizados nesta linha de pesquisa. O sistema teste IEEE 68 barras tem sido bastante utilizado para a predição da estabilidade transitória, sendo assim, o sistema escolhido para este trabalho. De posse do sistema teste, a metodologia para a elaboração do banco de dados é descrita abaixo.

## B.1 1º Passo: Encontrar os pontos de máxima e mínima operação do sistema teste sem que o mesmo perda a estabilidade

Com auxílio do Matlab, deve-se alterar o cartão base do Anarede quanto ao seu carregamento. Este arquivo pode ser visualizado através do PWF como mostra a Figura 20. Posteriormente, fazer os testes no Anarede carregando o novo cartão para verificar se o mesmo permanece estável ou não. Esse procedimento é realizado até encontrar o nível de máximo e mínimo carregamento do SEP em estudo.

Figura 20 – Cartão PWF ANAREDE

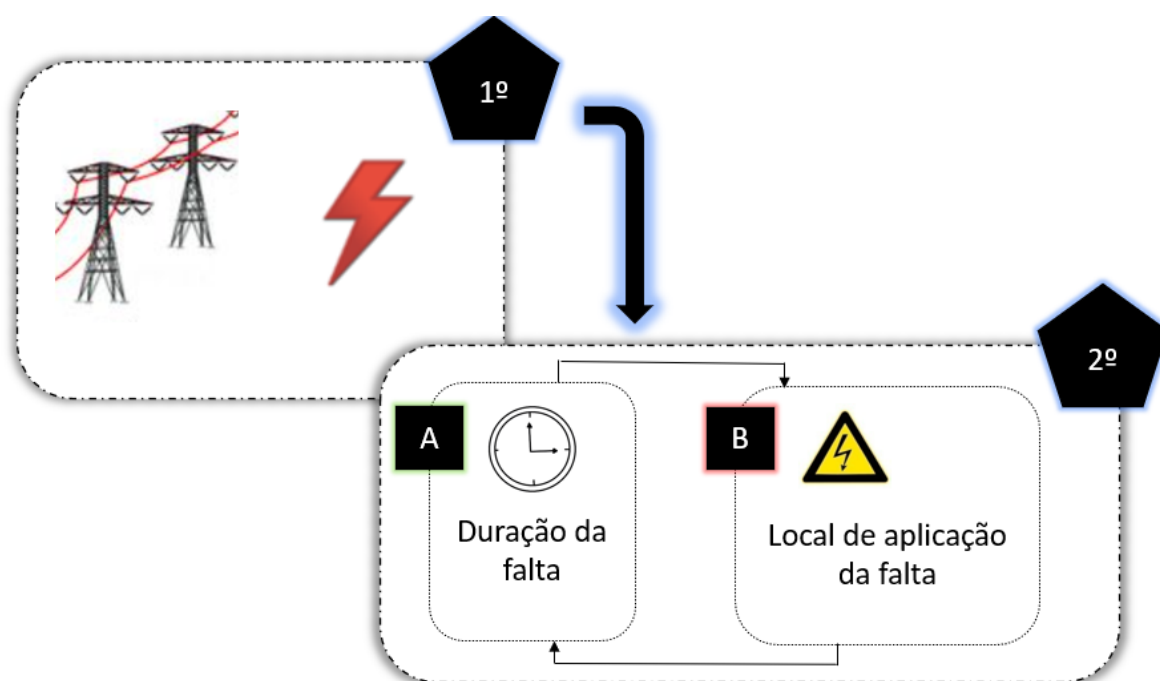
NETS_NYPS_vb.pwf		4_NETS_NYPS_vb17.pwf										
001	<input type="checkbox"/>	TITU										
002	<input type="checkbox"/>	**** New-England / New-York Test System ****										
003	<input type="checkbox"/>	DBAR										
004		( 0   1   2   3   4   5   6   7										
005		(234567890123456789012345678901234567890123456789012345678901234567890										
006		(Num)OETGb( name )Gl( V)( A)( Pg)( Qg)( Qn)( Qm)(Bc ) ( Pl)( Ql)( Sh)Are(Vf)										
007		01 1 Barra01	1045	0. 250.	0. -999. 9999.	0. 0.	0. 0.	2				
008		02 1 Barra02	0980	0. 545.	0. -999. 9999.	0. 0.	0. 0.	2				
009		03 1 Barra03	0983	0. 650.	0. -999. 9999.	0. 0.	0. 0.	2				
010		04 1 Barra04	0997	0. 632.	0. -999. 9999.	0. 0.	0. 0.	2				
011		05 1 Barra05	1011	0. 505.	0. -999. 9999.	0. 0.	0. 0.	2				
012		06 1 Barra06	1050	0. 700.	0. -999. 9999.	0. 0.	0. 0.	2				
013		07 1 Barra07	1063	0. 560.	0. -999. 9999.	0. 0.	0. 0.	2				
014		08 1 Barra08	1030	0. 540.	0. -999. 9999.	0. 0.	0. 0.	2				
015		09 1 Barra09	1025	0. 800.	0. -999. 9999.	0. 0.	0. 0.	2				
016		10 1 Barra10	1010	0. 500.	0. -999. 9999.	0. 0.	0. 0.	1				
017		11 1 Barra11	1000	0.1000.	0. -999. 9999.	0. 0.	0. 0.	1				
018		12 1 Barra12	1015	0.1350.	0. -999. 9999.	0. 0.	0. 0.	1				
019		13 1 Barra13	1011	0.3591.	0. -999. 9999.	0. 0.	0. 0.	1				
020		14 1 Barra14	1000	0.1785.	0. -999. 9999.	0. 0.	0. 0.	3				
021		15 1 Barra15	1000	0.1000.	0. -999. 9999.	0. 0.	0. 0.	4				
022		16 2 Barra16	1000	0.4000.	0. -999. 9999.	0. 0.	0. 0.	5				
023		17 0 Barra17	1000	0. 0.	0.	6000.	300.	1				
024		18 0 Barra18	1000	0. 0.	0.	2470.	123.	5				
025		19 0 Barra19	1000	0. 0.	0.	0.	0.	2				
026		20 0 Barra20	1000	0. 0.	0.	680.	103.	2				
027		21 0 Barra21	1000	0. 0.	0.	274.	115.	2				
028		22 0 Barra22	1000	0. 0.	0.	0.	0.	2				
029		23 0 Barra23	1000	0. 0.	0.	248.	85.	2				
030		24 0 Barra24	1000	0. 0.	0.	309.	-92.	2				
031		25 0 Barra25	1000	0. 0.	0.	224.	47.	2				
032		26 0 Barra26	1000	0. 0.	0.	139.	17.	2				
033		27 0 Barra27	1000	0. 0.	0.	281.	76.	2				
034		28 0 Barra28	1000	0. 0.	0.	206.	28.	2				
035		29 0 Barra29	1000	0. 0.	0.	284.	27.	2				
036		30 0 Barra30	1000	0. 0.	0.	0.	0.	1				
037		31 0 Barra31	1000	0. 0.	0.	0.	0.	1				
038		32 0 Barra32	1000	0. 0.	0.	0.	0.	1				
039		33 0 Barra33	1000	0. 0.	0.	112.	0.	1				
040		34 0 Barra34	1000	0. 0.	0.	0.	0.	1				
041		35 0 Barra35	1000	0. 0.	0.	0.	0.	1				
042		36 0 Barra36	1000	0. 0.	0.	102.	-19.5	1				

Fonte: Autoria própria.

## B.2 2º Passo: variação dos pontos de aplicação de falta e duração

Para o sistema com carga máxima, nominal e mínima. Aplicar faltas trifásicas nas linhas disponíveis do sistema teste em análise, lembrando de excluir as linhas que provocam o ilhamento dos geradores. Esse procedimento deve ser realizado de maneira isolada, primeiro para o SEP com carga nominal, depois para o SEP com carga máxima e por fim para o SEP com carga mínima. A aplicação da falta deve conter diversos tempos de duração, assim são testados de forma determinística. É comum que a variação aconteça no intervalo de 200 a 700 ms, com discretização de 50 ms. Esse procedimento é feito alterando os cartões bases do Anatem com auxílio do Matlab. Uma vez alterado os cartões, os mesmos são carregados para o Anatem, onde as simulações são realizadas. A Figura 21 ilustra o procedimento descrito. E a Figura 22 mostra como é aplicada a perturbação, sua duração e o percentual de aplicação na linha. Esse procedimento é realizado dentro dos cartões do Anatem chamados STB. A Figura 23 Mostra um resumo de como a variação das faltas e seu tempo de duração foram aplicados neste trabalho.

Figura 21 – Variação das faltas



Fonte: Autoria própria.



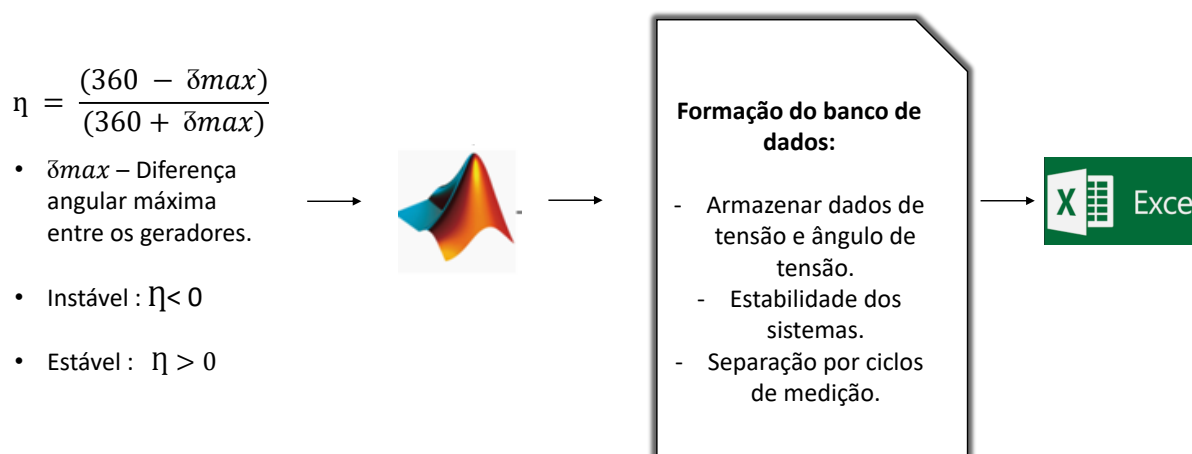


## B.3 3º Passo: Extração de característica sobre a estabilidade do sistema

De posse de todos os cartões do Anatem simulados, basta carrega-los para o Matlab, em que o índice TSI será calculado com a janela de tempo desejada, no caso deste trabalho 10 ciclos. Após efetuar os cálculos, os sistema serão classificados quanto a sua estabilidade e posteriormente armazenados em vetores que serão transferidos para planilhas do Excel.

Todas as respostas e variáveis desejadas como níveis de tensão e ângulo de tensão devem ser armazenadas no Excel para que posteriormente sejam reorganizadas para o treinamento das RNAs. A Figura 24 demonstra o procedimento realizado.

Figura 24 – Extração de características

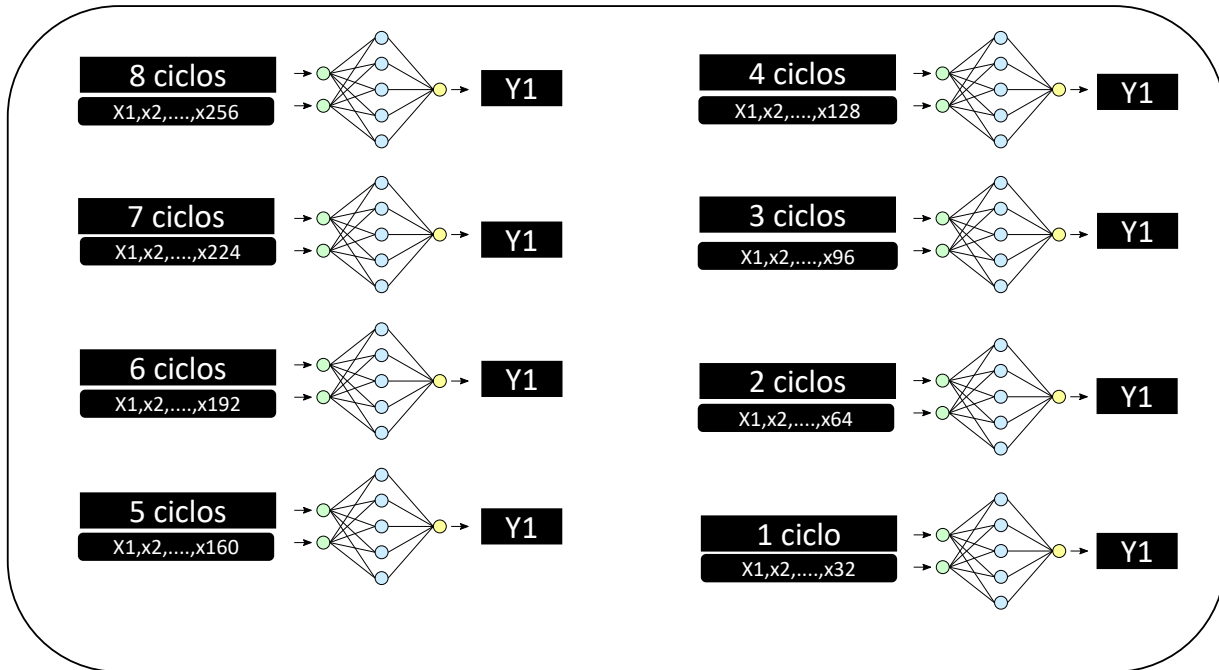


Fonte: Autoria própria.

## B.4 4º passo: Treinamento das RNAs

As planilhas do Excel são formadas por dados de entrada e dados de saída separadamente. Os dados de entrada possuem um vetor com dados de tensão e ângulo de tensão, todos em uma sequência organizado pela quantidade de ciclos. Desta forma o tamanho dos vetores é definido de acordo com a quantidade de ciclos, como foi explicado no capítulo 4 deste trabalho. A saída, por sua vez, sempre será um vetor unitário. A Figura 25 demonstra a variação dos vetores.

Figura 25 – Variação dos vetores por ciclo



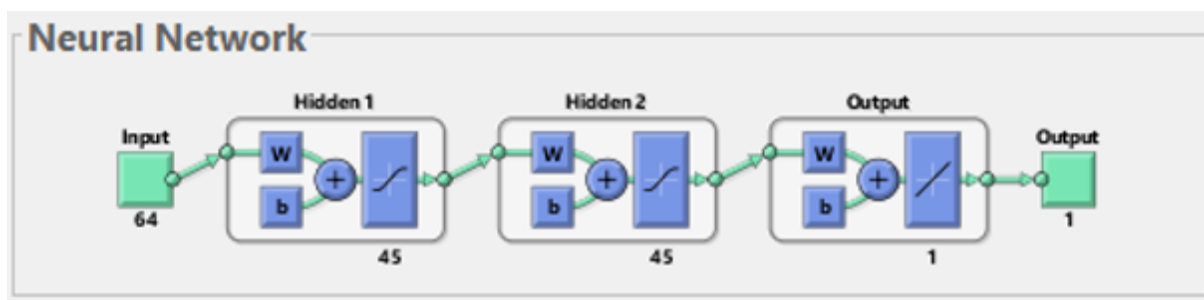
Fonte: Autoria própria.

Neste trabalho 8 RNAs foram treinadas, deste modo foi necessário criar 9 planilhas no Excel, das quais 8 planilhas contem os dados de entrada da rede, uma planilha para cada ciclo, e uma única planilha contem os dados de saída da rede. Esta última planilha é comum para o treinamento de todas as RNAs isso por que a saída das RNAs treinadas tem como objetivo prever a estabilidade do sistema que pode ser apenas estável ou instável, sendo assim o tamanho do vetor não é alterado. A planilha com os dados de saída são formadas através a partir do índice TSI calculado para 10 ciclos. Essa quantidade de ciclos fornece uma análise precisa quanto ao funcionamento do SEP no período pós falta.

A classificação da estabilidade é feita com auxílio do Matlab. O índice TSI é calculado fazendo a leitura dos cartões simulados pelo Anatem, os dados utilizados são os valores do ângulo do rotor dos geradores. Caso o índice TSI possua um valor maior que zero ele é classificado como estável e recebe o valor de 1. Caso o índice TSI seja menor que zero ele é classificado como instável e recebe o valor de -1.

Os valores de 1 e -1 foram definidos para facilitar o treinamento das RNAs, pois a função de ativação utilizado nas camadas intermediárias é do tipo tangente, a qual possui uma variação de -1 a 1, enquanto a função de saída é uma função linear que recebe valores de 1 e -1. A Figura 26 mostra uma das arquiteturas testada neste trabalho.

Figura 26 – Arquitetura de uma RNA



Fonte: Autoria própria.