



UNIVERSIDADE FEDERAL DO MARANHÃO  
CENTRO DE CIÊNCIAS DE BALSAS  
CURSO DE ENGENHARIA ELÉTRICA

JOÃO VITOR BARROS DE ARAÚJO

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA  
ESTIMAÇÃO DE MODOS ELETROMECÂNICOS EM SISTEMAS  
ELÉTRICOS DE POTÊNCIA**

BALSAS-MA  
2026

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).  
Diretoria Integrada de Bibliotecas/UFMA

Barros de Araujo, João Vitor.

APLICAÇÃO DE REDES NEURAI ARTIFICIAIS PARA ESTIMAÇÃO  
DE MODOS ELETROMECÂNICOS EM SISTEMAS ELÉTRICOS DE POTÊNCIA  
/ João Vitor Barros de Araujo. - 2026.

53 p.

Orientador(a): Raimundo Nonato Diniz Costa Filho.

Curso de Engenharia Elétrica, Universidade Federal do  
Maranhão, Balsas - Ma, 2026.

1. Modos Eletromecânicos. 2. Estabilidade A Pequenas  
Perturbações. 3. Redes Neurais Artificiais. 4.  
Multilayer Perceptron. 5. Sistemas Elétricos de Potência.  
I. Diniz Costa Filho, Raimundo Nonato. II. Título.

JOÃO VITOR BARROS DE ARAÚJO

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA  
ESTIMAÇÃO DE MODOS ELETROMECÂNICOS EM SISTEMAS  
ELÉTRICOS DE POTÊNCIA**

TCC apresentado ao Curso de Engenharia Elétrica da Universidade Federal do Maranhão, para obtenção do título de Bacharel em Engenharia Elétrica.

Examinado por:

---

Prof. Dr. Raimundo Nonato Diniz Costa Filho

---

Prof. Me. Gustavo Araújo de Andrade

---

Prof. Dr. Pedro Bezerra Leite Neto

BALSAS-MA  
2026

## DEDICATÓRIA

Dedico este trabalho à minha família, que sempre foi à base de todo o meu esforço e perseverança. À minha esposa e à minha filha, pelo amor, compreensão e apoio incondicional, que me deram forças para seguir em frente nos momentos mais desafiadores. À minha mãe e à minha irmã, pelo incentivo constante, pelos ensinamentos e pela presença fundamental ao longo de toda esta caminhada.

## AGRADECIMENTOS

Primeiramente, agradeço a Deus, por me conceder saúde, sabedoria, força e perseverança ao longo de toda esta jornada acadêmica, permitindo que eu superasse os desafios e alcançasse este importante objetivo.

Agradeço à minha esposa, Giselle Caroline Carvalho Ribeiro, pelo amor, paciência, compreensão e apoio incondicional em todos os momentos, sendo meu alicerce nos períodos mais difíceis. À minha filha, Melissa Barros Carvalho, que, mesmo de forma indireta, foi fonte constante de motivação e inspiração para seguir em frente.

À minha mãe, Ana Maria Martins Barros, pelo incentivo contínuo, pelos ensinamentos e pelo apoio irrestrito ao longo de toda minha vida acadêmica e pessoal. À minha irmã, Ana Vitória Barros de Araújo, pelo carinho, apoio e companheirismo.

Agradeço de forma especial ao meu orientador, Prof. Dr. Raimundo Nonato Diniz Costa Filho, pela orientação, dedicação, paciência e valiosas contribuições científicas, fundamentais para o desenvolvimento e conclusão deste trabalho.

Estendo meus agradecimentos a todos os professores do curso de Engenharia Elétrica do CCBL, que contribuíram de maneira significativa para minha formação acadêmica e profissional, compartilhando conhecimentos, experiências e incentivo ao longo do curso. Por fim, agradeço aos meus colegas de curso, que estiveram presentes durante todo o percurso acadêmico, compartilhando aprendizados, desafios e conquistas, tornando essa caminhada mais rica e significativa.

## RESUMO

Este trabalho propõe uma metodologia baseada em Redes Neurais Artificiais do tipo Multilayer Perceptron (MLP) para a estimação dos coeficientes de amortecimento de modos eletromecânicos. Os dados utilizados no treinamento, validação e teste da rede neural foram obtidos por meio de simulações realizadas no Power System Analysis Toolbox (PSAT), a partir da análise modal clássica de um sistema multimáquinas. A metodologia foi aplicada ao sistema teste IEEE de 9 barras, considerando diferentes condições operativas e contingências. Os resultados demonstraram que a MLP foi capaz de estimar com elevada precisão os coeficientes de amortecimento dos modos analisados, apresentando baixos erros absolutos e percentuais, inclusive para modos fracamente amortecidos. Os resultados indicam que a abordagem proposta é promissora para aplicações de monitoramento dinâmico e suporte à tomada de decisão em sistemas elétricos de potência.

**Palavras-chave:** Modos eletromecânicos. Estabilidade a pequenas perturbações. Redes neurais artificiais. Multilayer Perceptron. Sistemas elétricos de potência

## ABSTRACT

This work proposes a methodology based on Artificial Neural Networks, specifically a Multilayer Perceptron (MLP), for the estimation of damping coefficients of electromechanical modes. The data used for training, validation, and testing were obtained from simulations performed using the Power System Analysis Toolbox (PSAT), based on classical modal analysis of a multimachine system. The proposed methodology was applied to the IEEE 9-bus test system under different operating conditions and contingencies. The results show that the MLP was able to estimate the damping coefficients of the analyzed modes with high accuracy, presenting low absolute and percentage errors, even for weakly damped modes. These findings indicate that the proposed approach is a promising alternative for dynamic monitoring and decision support applications in electric power systems.

**Key-words:** Electromechanical modes. Small-signal stability. Artificial neural networks. Multilayer Perceptron. Electric power systems.

## LISTA DE TABELA

Tabela 1: Fluxo de carga sem faltas no sistema IEEE de 9 barras .....	39
Tabela 2: Resultados do fluxo de potência sem falta .....	39

## SUMÁRIO

CAPÍTULO 1 .....	9
1.1. INTRODUÇÃO .....	9
1.2. OBJETIVOS .....	10
1.2.1.OBJETIVO GERAL .....	10
1.2.2.OBJETIVOS ESPECÍFICOS .....	10
1.3. JUSTIFICATIVA.....	10
1.4. METODOLOGIA .....	12
1.5. ESTRUTURA DO TRABALHO.....	12
CAPÍTULO 2.....	14
2.1. ESTABILIDADE DE SISTEMAS ELÉTRICOS .....	14
2.2. ESTABILIDADE ANGULAR A PEQUENAS PERTURBAÇÕES.....	14
2.3. ESTABILIDADE TRANSITÓRIA .....	16
2.4. MODOS ELETROMECAÑICOS.....	17
CAPÍTULO 3.....	22
3.1. TOOLBOX UTILIZADA DE REDES NEURAIIS E ARQUITETURA EMPREGADA .....	22
3.2. METODOLOGIA EMPREGADA .....	28
CAPÍTULO 4.....	38
4.1. SISTEMA TESTE.....	38
4.2. RESULTADOS.....	40
Capítulo 5.....	49
5.1.CONCLUSÕES.....	49
5.2.TRABALHOS FUTUROS.....	50
REFERÊNCIAS .....	51

# CAPÍTULO 1

## 1.1. INTRODUÇÃO

A estabilidade e a operação segura de sistemas elétricos de potência são cruciais para o fornecimento contínuo e confiável de energia. Um aspecto fundamental dessa estabilidade reside na compreensão e monitoramento dos modos eletromecânicos, que são oscilações de baixa frequência que podem surgir em resposta a distúrbios no sistema. A identificação e a estimação precisas desses modos são essenciais para que os operadores possam tomar decisões rápidas e eficazes, prevenindo eventos em cascata e garantindo a integridade da rede (OSTOJIC; HEYDT, 1991).

A estabilidade a pequenas perturbações, refere-se à capacidade de um sistema elétrico de potência de permanecer em operação sincronizada após sofrer pequenas variações em suas condições normais de funcionamento, como pequenas mudanças de carga, oscilações na geração ou variações de tensão. Nessas situações, os geradores do sistema podem apresentar oscilações eletromecânicas de baixa frequência, que precisam ser naturalmente amortecidas para evitar o crescimento das oscilações e possíveis perdas de sincronismo.

Tradicionalmente, a avaliação da estabilidade transitória e a análise de modos oscilatórios têm sido realizadas por meio de métodos computacionais complexos e intensivos. No entanto, com a crescente complexidade dos sistemas de potência modernos, impulsionada pela integração de fontes de energia renováveis e pela expansão das redes, a necessidade de ferramentas mais rápidas e eficientes para a estimação de modos tornou-se premente. Sistemas de monitoramento de área ampla (WAMS), que fornecem grandes volumes de dados em tempo real, exigem algoritmos capazes de processar essa massa de informações de forma ágil e precisa (SATHEESH *et al.*, 2023).

Nesse contexto, as Redes Neurais Artificiais (RNAs) emergem como uma solução promissora. A capacidade das RNAs de aprender padrões complexos a partir de dados e de realizar inferências rápidas as torna particularmente adequadas para a estimação de modos eletromecânicos. Desde abordagens pioneiras que utilizam o reconhecimento de padrões no domínio da frequência para avaliar a estabilidade transitória (OSTOJIC; HEYDT, 1991), até técnicas mais avançadas baseadas em redes de memória de longo e curto prazo (LSTM) para

prever parâmetros de modos oscilatórios, as RNAs têm demonstrado um potencial significativo (SATHEESH *et al.*, 2023).

Além disso, a aplicação de *machine learning* e abordagens probabilísticas, como as que utilizam redes neurais artificiais sequenciais, também se mostra relevante para a estimação e previsão de harmônicos em sistemas de potência com monitoramento esparso (ZHAO, 2025).

Este trabalho explora a aplicação de redes neurais artificiais para a estimação de modos eletromecânicos em sistemas elétricos de potência, abordando a evolução das técnicas e a relevância dessas metodologias para os desafios atuais e futuros da operação de redes elétricas.

## **1.2. OBJETIVOS**

### **1.2.1.OBJETIVO GERAL**

Desenvolver uma metodologia baseada em Redes Neurais Artificiais (RNAs) para estimar os modos eletromecânicos em sistemas elétricos de potência.

### **1.2.2.OBJETIVOS ESPECÍFICOS**

Visando atingir o objetivo principal, alguns objetivos específicos são requeridos, entre eles:

- Realizar uma revisão bibliográfica aprofundada sobre as técnicas de estimação de modos eletromecânicos em sistemas elétricos de potência.
- Validar o desempenho do modelo proposto, comparando os resultados com a análise modal.
- Aplicar a metodologia proposta em um sistema multimáquinas.

## **1.3. JUSTIFICATIVA**

A necessidade de métodos eficientes e precisos para a estimação de modos eletromecânicos em sistemas elétricos de potência é justificada por diversos fatores críticos que afetam a segurança, a confiabilidade e a economia da operação da rede. A crescente complexidade e interconexão dos sistemas de potência, aliada à penetração cada vez maior de

fontes de energia renováveis intermitentes, introduz novos desafios e dinâmicas que exigem um monitoramento e controle mais sofisticados.

A estimativa de modos eletromecânicos é fundamental para garantir a estabilidade a pequenas perturbações em Sistemas Elétricos de Potência (SEP). Isso ocorre porque os modos eletromecânicos descrevem a forma como os geradores síncronos respondem após pequenas perturbações no sistema, como variações de carga, mudanças na geração ou pequenas faltas na rede elétrica. Após esses eventos, os geradores podem apresentar oscilações de velocidade e ângulo do rotor, que se propagam por todo o sistema elétrico. A análise desses modos permite identificar se tais oscilações serão naturalmente amortecidas ou se tendem a crescer com o tempo, podendo comprometer a estabilidade do sistema.

Além disso, uma identificação correta dos modos eletromecânicos possibilita compreender como diferentes grupos de máquinas interagem entre si durante as oscilações, permitindo prever condições que podem resultar em perda de sincronismo, desligamentos em cascata e até colapsos no fornecimento de energia. Dessa forma, a análise modal torna-se uma ferramenta essencial para o monitoramento, planejamento e operação segura de Sistemas Elétricos de Potência, auxiliando operadores na tomada de decisões rápidas e eficazes frente a condições de instabilidade (KUNDUR, 1994).

Outro motivo para o estudo da estimação de modos eletromecânicos é a possibilidade de um melhor monitoramento em tempo real da saúde dinâmica do sistema, avaliando se as oscilações inter áreas estão se aproximando de condições críticas. Com o avanço da tecnologia baseadas em dados, como as PMUs, tornou-se possível detectar modos de baixo amortecimento de maneira rápida e precisa, realizando uma correta estimação de frequências naturais e fatores de amortecimento. (ZHOU *et al.*, 2019).

A estimação de modos se torna importante, pois fornece informações fundamentais para o dimensionamento de controladores, como PSS (Power System Stabilizers), métodos baseados em modelos e baseados em medidas realizam a validação de dispositivos de amortecimento, garantido que o sistema se mantenha na estabilidade mesmo em condições de estresse. Dessa forma, a estimação modal é indispensável para a operação de sistemas modernos. (GUO; WU; CHEN, 2020).

Um dos principais argumentos para a aplicação de Redes Neurais Artificiais reside na sua capacidade de lidar com a natureza não linear e dinâmica dos sistemas de potência.

Métodos tradicionais, muitas vezes baseados em modelos lineares ou simplificados, podem não ser adequados para capturar a complexidade das oscilações eletromecânicas em cenários operacionais variados. A abordagem de reconhecimento de padrões no domínio da frequência, proposta em estudos iniciais já demonstrava a viabilidade de sistemas adaptativos para o monitoramento da estabilidade transitória, minimizando falsos alarmes e falsas rejeições (OSTOJIC; HEYDT, 1991).

Além disso, a proliferação de sistemas de monitoramento de área ampla (WWAMS) e a consequente disponibilidade de grandes volumes de dados em tempo real criam uma oportunidade e uma demanda por algoritmos que possam processar essas informações de forma rápida e eficiente.

#### **1.4. METODOLOGIA**

Para o desenvolvimento da presente pesquisa proposta será adotada a metodologia da pesquisa científica.

- I. Revisão Bibliográfica:** Esta etapa consiste em uma revisão da literatura sobre as técnicas utilizadas na estimação de modos eletromecânicos em sistemas elétricos de potência. O objetivo é compreender e identificar lacunas e tendências.
- II. Implementação das RNAs:** o software Matlab será empregado para implementar as RNAs. Os dados para treinamento, validação e testes serão obtidos através do PSAT.
- III. Simulações computacionais em sistemas testes:** para testar a metodologia empregada será utilizado um sistema multimáquinas. Os resultados obtidos pela metodologia proposta serão comparados com a metodologia tradicional (análise modal).

#### **1.5. ESTRUTURA DO TRABALHO**

Este trabalho está estruturado em cinco capítulos. O Capítulo 1 apresenta a introdução, os objetivos geral e específicos, a justificativa do estudo, bem como a metodologia adotada e a organização do trabalho. No Capítulo 2, são abordados os fundamentos teóricos relacionados à estabilidade de sistemas elétricos de potência, com ênfase na estabilidade angular a pequenas perturbações e na caracterização dos modos eletromecânicos, além da revisão das principais técnicas baseadas em modelos e em medições para a estimação modal.

O Capítulo 3 descreve as ferramentas computacionais e a metodologia empregada, detalhando a arquitetura da rede neural do tipo Multilayer Perceptron, o funcionamento da toolbox utilizada no MATLAB e os procedimentos adotados para a geração dos dados, treinamento, validação e teste da rede neural. No Capítulo 4, são apresentados o sistema teste IEEE de 9 barras e a análise detalhada dos resultados obtidos, incluindo a comparação entre os valores reais e estimados dos modos eletromecânicos e a avaliação do desempenho do modelo por meio de métricas de erro. Por fim, o Capítulo 5 reúne as conclusões do trabalho, destacando as principais contribuições, limitações e sugestões para trabalhos futuros.

## **CAPÍTULO 2**

### **2.1. ESTABILIDADE DE SISTEMAS ELÉTRICOS**

Para que ocorra uma operação segura e eficiente dos sistemas elétricos de potência, é de extrema importância o se ter controle sobre a estabilidade angular que está relacionada na capacidade em que as máquinas síncronas possuem de continuar em sincronismo umas com as outras, mesmo depois da ocorrência de uma perturbação no sistema elétrico. De forma direta, representa a habilidade de resistir e se recuperar de uma ocorrência de distúrbio que causam variações no ângulo do rotor das máquinas geradoras (COSTA FILHO, 2018).

O tema de estabilidade está diretamente associado à confiabilidade da operação dos sistemas de energia elétrica, quando ocorre uma falha grave, como um curto-circuito, uma desconexão de linha ou uma variação súbita de carga, é essencial que o sistema consiga retornar ao seu estado de equilíbrio sem perda de sincronismo entre os geradores (KUNDUR, 1994). Caso isso não aconteça, há o risco de desligamento em cascata e colapso do sistema elétrico, com sérias consequências econômicas e operacionais.

### **2.2. ESTABILIDADE ANGULAR A PEQUENAS PERTURBAÇÕES**

A estabilidade a pequenas perturbações está associada à resposta do sistema a variações leves, como pequenas flutuações de carga ou pequenas variações de tensão. Nesses casos, o sistema é analisado a partir das equações diferenciais e algébricas que o descrevem, em torno de um ponto de equilíbrio. Essa abordagem permite estudar o comportamento dinâmico em curtos intervalos de tempo, geralmente entre 10 e 20 segundos após a perturbação (KUNDUR, 1994).

A representação matemática desse comportamento pode ser expressa na forma de espaço de estados, conforme a equação:

$$\Delta \dot{x} = A \Delta x \quad (1)$$

Em que  $\Delta x$  é o vetor das variáveis de estado perturbadas e  $A$  representa a matriz de estados do sistema. Os autovalores dessa matriz ( $\lambda$ ) fornecem informações cruciais sobre a estabilidade. Se todos os autovalores possuem parte real negativa, o sistema é estável; caso contrário, torna-se instável (COSTA FILHO, 2018). Um par de autovalores complexos conjugados pode ser descrito por:

$$\lambda_i = \sigma_i \pm j\omega \quad (2)$$

Em que  $\sigma$ , define o amortecimento e  $\omega$  está relacionado à frequência de oscilação.

De forma prática, a estabilidade a pequenas perturbações é importante para o estudo de oscilações de baixa frequência (LFOs - *Low Frequency Oscillations*), que surgem devido à interação eletromecânica entre geradores. Essas oscilações são classificadas em dois tipos principais: os modos locais, que envolvem uma única unidade geradora oscilando em relação ao sistema, e os modos interárea, nos quais grupos de geradores em diferentes regiões oscilam entre si. Esses fenômenos podem provocar variações perceptíveis na frequência do sistema, comprometendo a qualidade da energia elétrica (COSTA FILHO, 2018).

Para compreender melhor essas oscilações, emprega-se a análise modal da matriz de estados  $A$ . Os autovetores associados a cada autovalor revelam como as variáveis físicas participam das oscilações. A influência de cada variável em um modo específico é determinada pelos fatores de participação ( $P_{ki}$ ), definidos como o produto dos autovetores direito e esquerdo correspondentes:

$$p_{ki} = \psi_{ik} \phi_{ki} \quad (3)$$

A equação 3 representa o fator de participação, que indica o quanto uma determinada variável de estado participa de um modo oscilatório específico, permitindo identificar quais estados do sistema mais influenciam determinada oscilação eletromecânica. Na equação,  $p_{ki}$  representa o fator de participação da variável de estado  $k$  no modo  $i$ . Quanto maior o valor desse fator, maior é a influência daquela variável sobre o modo oscilatório analisado.

O termo  $\phi_{ki}$  corresponde ao elemento do autovetor à direita associado ao modo  $i$ . Os autovetores à direita descrevem como os estados do sistema se manifestam em determinado modo oscilatório, ou seja, indicam o formato da oscilação e quais variáveis apresentam maior amplitude naquele modo.

Já o termo  $\psi_{ik}$  representa o elemento do autovetor à esquerda associado ao mesmo modo  $i$ . Diferentemente do autovetor à direita, o autovetor à esquerda está relacionado à sensibilidade do modo em relação às variáveis de estado, mostrando o quanto aquele modo é afetado por alterações em determinado estado do sistema.

### 2.3. ESTABILIDADE TRANSITÓRIA

Enquanto as pequenas perturbações envolvem distúrbios sutis, a estabilidade transitória refere-se à capacidade do sistema de suportar grandes perturbações como curtos-circuitos, perda súbita de geração ou desconexão de linhas de transmissão. Nesses casos, o comportamento é fortemente não linear e não pode ser analisado apenas por métodos de linearização. A resposta transitória define se o sistema conseguirá manter o sincronismo ou se os geradores perderão a coerência angular após o evento (COSTA FILHO, 2018).

A análise da estabilidade transitória utiliza dois tipos principais de métodos. O primeiro é o método indireto, baseado em simulações no domínio do tempo. Esse método é detalhado e preciso, mas exige elevado esforço computacional. O segundo é o método direto, que busca avaliar a estabilidade por meio de funções de energia, sem necessidade de simulação temporal extensa (KUNDUR, 1994).

O método direto é fundamentado no conceito de Função de Energia Transitória (TEF - *Transient Energy Function*), inspirada nas ideias de Lyapunov sobre estabilidade. A função descreve a energia armazenada no sistema, considerando que a condição de estabilidade é satisfeita se a derivada temporal da função for não positiva, ou seja,  $V'(x) \leq 0$ .

A principal métrica derivada dessa análise é o Tempo Crítico de Eliminação (T.), que representa o intervalo máximo em que um sistema de proteção pode atuar para eliminar a falta, garantindo que o sistema permaneça estável após o distúrbio. Na prática, o cálculo do  $T_c$  orienta o projeto e o ajuste de relés de proteção, assegurando que eles desliguem os circuitos em tempo hábil para evitar a perda de sincronismo (SAUER, 1998).

A estabilidade angular, em suas duas vertentes, desempenha papel essencial na operação de sistemas elétricos modernos. Em redes interligadas de grande porte, como as que compõem os sistemas nacionais de transmissão, o equilíbrio dinâmico entre geração e consumo é constantemente desafiado. A introdução de fontes renováveis, como a energia eólica e solar, traz novas variáveis, uma vez que essas fontes são intermitentes e apresentam


características eletromecânicas distintas das máquinas síncronas convencionais (CAÑIZARES *et al.*, 2018).

## 2.4. MODOS ELETROMECAÑICOS

Os modos oscilatórios de baixa frequência, também conhecidos como modos eletromecânicos, são oscilações naturais que surgem nos sistemas elétricos de potência quando há um desequilíbrio momentâneo entre a potência mecânica fornecida pelas turbinas e a potência elétrica entregue à rede pelos geradores. Em outras palavras, após uma pequena perturbação no sistema, como uma variação de carga ou uma alteração na geração, os rotores dos geradores passam a acelerar e desacelerar levemente até tentarem retornar ao sincronismo. Esse movimento oscilatório ocorre devido ao acoplamento dinâmico entre o torque mecânico aplicado ao eixo do gerador e o torque elétrico produzido pela interação com a rede elétrica. Quando o sistema possui amortecimento adequado, essas oscilações diminuem gradativamente; caso contrário, podem crescer e comprometer a estabilidade do sistema.

Segundo Kundur (1994), os modos eletromecânicos podem ser classificados em três categorias principais. Os modos locais, geralmente na faixa de 1 a 3 Hz, representam oscilações entre um gerador ou um pequeno grupo de geradores em relação ao restante do sistema elétrico. Já os modos inter-área, normalmente entre 0,1 e 1 Hz, ocorrem quando grandes grupos de geradores de uma região oscilam contra grupos de outra região, sendo comuns em sistemas interligados de grande porte. Por fim, os modos de controle ou intra-planta estão associados à interação entre os geradores e seus sistemas automáticos de controle, como o Regulador Automático de Tensão (AVR – *Automatic Voltage Regulator*) e o Estabilizador de Sistema de Potência (PSS – *Power System Stabilizer*), influenciando diretamente o amortecimento das oscilações e a estabilidade dinâmica do sistema.

Figura 1: Classificação dos modos eletromecânicos em sistemas de potência



Fonte: Samai & Subudhi (2019)

A Figura 1, retirada de Samai & Subudhi (2019), apresenta sinais de teste compostos por senoides amortecidas, utilizados para representar oscilações eletromecânicas típicas de sistemas elétricos de potência. Os sinais possuem amplitude unitária e diferem de acordo com a frequência e em relação ao sinal-ruído (SNR). As Figuras (a) e (b) correspondem a um modo de baixa frequência (0,4 Hz), característico de oscilações interárea, considerando respectivamente condições de baixo ruído (SNR = 30 dB) e alto nível de ruído (SNR = 10 dB). As Figuras (c) e (d) apresentam um modo de frequência mais elevada (1,5 Hz), associado a modos locais, também sob condições de 30 dB e 10 dB de SNR, respectivamente. Nota-se que, embora os modos locais apresentem maior número de oscilações no mesmo intervalo de tempo, eles também são significativamente afetados pelo ruído.

A estabilidade de cada modo é diretamente relacionada ao seu coeficiente de amortecimento, que deve ser positivo e suficientemente elevado. Pequenas variações na topologia, carregamento ou parâmetros de controle podem reduzir significativamente o amortecimento dos modos. (GIBBARD *et al.*, 2015).


Segundo Rogers (1996) a redução do amortecimento dos modos eletromecânicos é uma das principais razões que causam a instabilidade oscilatória. Quando isso ocorre, e o

amortecimento se torna insuficiente, pequenas perturbações pode ser a razão de oscilações de magnitudes crescente, afetando a operação segura do sistema elétrico de potência.

Na literatura podemos encontrar dois grupos de técnicas para calcular os modos eletromecânicos em sistemas elétricos: técnicas baseadas em modelos e técnicas baseadas em medições.

As técnicas baseadas em modelo utilizam uma representação matemática do sistema de potência, definindo equações diferenciais algébricas com finalidade de determinar os modos eletromecânicos, por meio de análise dos autovalores da matriz de estados. A abordagem clássica desse método se baseia em linearizar o SEP ao redor de um ponto de operação obtendo o modelo em espaço de estado (matrizes A, B, C e D). Os autovalores e frequência podem ser obtidos através do cálculo dos autovalores A, ou seja, da matriz de estado. Essa abordagem clássica é a referência mais tradicional, porém limitada pelo custo computacional (PEPICIELLO; VACCARO, 2021).

Figura 2: Modelo de análise modal (autovalores)



Autor: Dorado *et al.*, (2020)

A Figura 2 representa a interpretação dos autovalores do sistema linearizado no plano complexo  $\sigma - j\omega$ , conforme a formulação clássica da análise de estabilidade a pequenas perturbações, nessa representação, a parte real dos autovalores ( $\sigma$ ) está diretamente associada ao coeficiente de amortecimento dos modos eletromecânicos, enquanto a parte imaginária ( $\omega$ ) corresponde à frequência angular das oscilações. Autovalores localizados no semiplano esquerdo indicam modos estáveis, autovalores com parte real positiva caracterizam modos instáveis, podendo resultar em oscilações de amplitude crescente. (Dorado *et al.*, 2020).

Pepiciello e Vaccaro (2021) propõem uma abordagem *black-box* para acelerar a análise de estabilidade a pequenas perturbações em sistemas elétricos de potência, baseada em uma rede neural artificial feedforward do tipo *Multilayer Perceptron* (MLP), com arquitetura rasa (*shallow neural network*), composta por uma camada de entrada, uma única camada oculta e uma camada de saída. A rede é treinada de forma supervisionada a partir de resultados obtidos por meio da *Small-Signal Stability Analysis* (SSSA) baseada em modelo, executada offline para múltiplos cenários operativos gerados por amostragem paramétrica. As entradas da rede correspondem às variáveis do sistema associadas ao ponto de operação e aos parâmetros dinâmicos, enquanto as saídas representam índices de estabilidade, como as razões de amortecimento dos modos eletromecânicos, permitindo significativa redução do tempo computacional sem perda de coerência física do modelo.

Outra técnica baseada em modelo proposta por Chen & Hsu (1991) é a utilização de RNA para classificar se uma máquina síncrona está estável ou instável, utilizando como referência análise modais do modelo de Heffron-Philips. A referida RNA recebe variáveis como potência ativa, fator de potência e ajustes do PSS, e utiliza disso para aprender os limites de estabilidade com base nos autovalores do sistema.

As técnicas de medição utilizam sinais medidos via PMU (geralmente tensões, correntes e potências), com o intuito de estimar modos eletromecânicos sem a necessidade de um modelo. Um exemplo proposto por Yuefan Wang *et al.* (2024) utiliza o método de Prony, que realiza o ajuste de uma soma de exponenciais amortecidas ao sinal medido e permite a extração das frequências, amortecimento, amplitude e fase dos modos. Este método é amplamente utilizado, porém é sensível ao ruído.

Já o método *forward and Backward extended prony* (FBEP), resolve essa limitação com a utilização simultânea dos polinômios forward e backward, com o intuito de eliminar modos espúrios e a identificação dos pólos reais do sistema com alta precisão, essa técnica é uma das variantes mais robustas do prony (ZHAO; LOPARO, 2017). Wang *et al.* (2024)

demonstram que a combinação de Prony com algoritmos genéticos melhora a extração modal sob ruído, obtendo estimativas mais precisas que as fornecidas por métodos de filtragem tradicionais.

Outra técnica bastante utilizada é o ESPRIT (*Estimation of Signal Parameters via Rotational Invariance Techniques*) que explora as propriedades de invariância rotacional de vetores de dados e realiza estimativas modais por análise de subespaços e decomposição SVD, esse método é mais robusto ao ruído do que o Prony, porém mais caro computacionalmente (TRIPATHY; SRIVASTAVA; SINGH, 2011).

Esse método proposto por Tripathy, Srivastava & Singh (2011), é uma versão modificada do TLS-ESPRIT, projetada para lidar com ruído gaussiano colorido, típico de sinais de PMUs após filtragem antialiasing. Essa técnica utiliza de duas relações de invariância rotacional, transformando o sinal para uma base ortogonal, dessa forma resultando em estimativas mais precisas. Esse método se destaca pela robustez aplicada em sistemas reais.

Shen & Ding (2019), apresentam a rede neural EDSNN (*Exponentially Damped Sinusoidal Neural Network*), que foi desenvolvida para representar sinais em forma de somas de senóides amortecidas. Nessa arquitetura a estimação dos modos eletromecânicos ocorre diretamente nos pesos da rede após treinamento com Levenberg - Marquardt. Esse método trata-se de uma combinação entre formalismo matemático clássico com a utilização de aprendizado de máquina.

Métodos mais atuais para a estimação de métodos eletromecânicos utilizam de *deep learning* diretamente sobre séries temporais de PMUs, uma aplicação é a utilização de CNNs, TCNs e *Inception Networks* para classificar a estabilidade com base em padrões temporais, substituindo completamente o cálculo modal tradicional (DORADO *et al.*, 2020)

Muhammed *et al.* (2024) propõe a utilização de modelos de LSTM, CNN-LSTM e Conv-LSTM, que possuem a capacidade de realizar previsões dinâmicas de frequências e amortecimentos dos modos locais e inter-área, acompanhando sua evolução temporal. Essa técnica de *measurement-based* é a mais próxima da aplicação operacional em tempo real, pois realiza a estimação direta dos parâmetros modais sem exigir modelagens explícitas.

## CAPÍTULO 3

### 3.1. TOOLBOX UTILIZADA DE REDES NEURAIIS E ARQUITETURA EMPREGADA

As redes neurais artificiais com o passar do tempo vêm sendo bastante utilizadas como uma ferramenta de modelagem de sistemas não lineares, e nesse contexto uma aplicação é na estimação de modos eletromecânicos. As utilizações das RNAs geralmente funcionam a partir de aprendizado e mapeamento de janelas temporais de sinais PMU ou características extraídas desses sinais para estimativa de frequência e amortecimento modal (CAI *et al.*, 2022).

As aplicações de RNAs vão além somente da estimação de modos, elas também são utilizadas para a identificação de parâmetros dinâmicos como a inércia equivalente do sistema. Linaro *et al.* (2023) propõe que a inércia exerce influência direta sobre as oscilações eletromecânicas de baixa frequência, e a sua estimação utilizando convolutional neural networks, tem a função de avaliar o comportamento modal do sistema, especialmente com a alta penetração de fontes baseadas em conversores.

Cai *et al.* (2022) utiliza uma abordagem que une as técnicas clássicas de decomposição modal com uma RNA, realizando esse método híbrido. É proposto um algoritmo *Dynamic Mode Decomposition* (DMD) que tem a função de extrair componentes dinâmicos dos sinais, enquanto uma RNA *multilayer artificial neural networks* realiza a estimação final dos parâmetros modais. A estratégia de utilizar métodos híbridos, com a junção de clássicos com e técnicas de RNAs, faz com que a capacidade de aprendizado das redes neurais artificiais seja uma aliada às técnicas matemáticas complexas.

A utilização de RNAs pode ser empregada tanto para estimação de modos quanto para classificação de condições operativas, trazendo informações importantes para análise dinâmica e tomada de decisões. Estudos utilizando RNAs aplicadas às operações em SEP reforçam o potencial das redes neurais como ferramentas complementar no estudo de análise modal (MOJUMDER, 2022).

Um exemplo de RNA utilizada para análise é a *Multilayer Perceptron* (MLP), que é uma arquitetura clássica do tipo *feedforward*, composta por camadas totalmente conectadas e treinadas por meio do algoritmo de retro propagação do erro. Devido a sua estrutura simples

é uma rede neural que possui eficiência computacional em problemas envolvendo previsão, controle e estimação de parâmetros dinâmicos (OLATUNJI *et al.*, 2019).

No contexto de estimação de modos eletromecânicos, a MLP é frequentemente utilizada como um regressor que mapeia vetores de entrada, formada por janelas temporais de sinais PMU ou por características espectrais. Estudos demonstram que MLPs mesmo com número reduzido de camadas ocultas, são capazes de fornecer estimativas satisfatórias quando treinadas com conjuntos de dados representativos de diferentes condições operativas do sistema. (KHOKHAR; MEMON & KEERIO, 2013).


A rede MLP possui baixo custo computacional, o que torna adequado para aplicações onde se necessita de monitoramento contínuo, essa característica é particularmente importante em sistema de supervisão e controle, onde é necessário rapidez na obtenção das estimativas modais para detecção de oscilações mal amortecidas (BENTO *et al.*, 2024).

Entretanto, a literatura também aponta limitações na utilização de MLPs, devido a dependência de dados de treinamento e a dificuldade de interpretação física direta dos pesos e parâmetros internos da rede. Devido esse fator, é necessário que estimativas obtidas por MLP sigam os métodos clássicos de análise modal, garantido uma maior confiabilidade para aplicações em SEP (KHOKHAR; MEMON; KEERIO, 2013).

Dentro desse contexto, a utilização da *Multilayer Perceptron* para estimação de modos eletromecânicos demonstra ser uma prática eficiente, sendo adotado como regressor em métodos híbridos de estimação modal. O desempenho e custo computacional fazem com que a MLP seja uma escolha adequada para aplicação deste estudo, demonstrando possuir treinamento e validação consistentes.

O MATLAB possui um conjunto integrado de ferramentas para modelagem RNAs chamado *Deep Learning Toolbox*, essa toolbox fornece funções prontas para criação, treinamento, validação e teste de redes neurais. A rede *Multilayer Perceptron* é implementada como uma rede feedforward, composta por uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída, onde cada neurônio realiza uma combinação linear das entradas. Essa estrutura permite ao MLP aproximar funções não lineares complexas, característica que é essencial para problemas de regressão e estimação de parâmetros (MATHWORKS, 2024).

Figura 3: Arquitetura rede Multilayer Perceptron



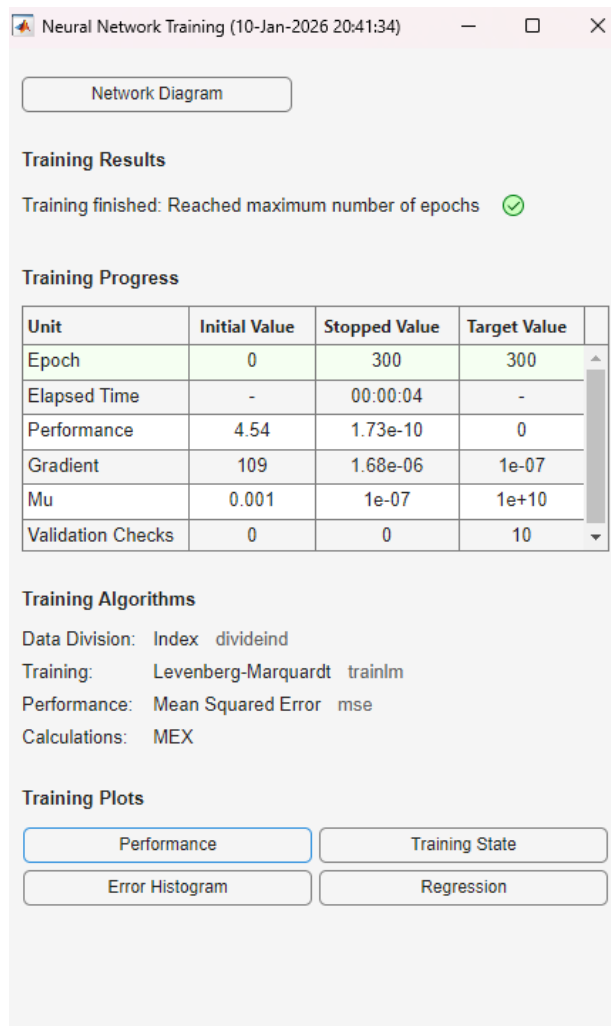
Fonte: adaptado de Moghadam (2022)

A Figura 3 ilustra uma arquitetura típica de uma rede neural MLP utilizada no MATLAB, a estrutura é definida em camadas e o fluxo de informação da entrada para a saída. Cada neurônio realiza uma combinação linear ponderada das entradas, adicionada de um termo de bias, seguida da aplicação de uma função de ativação não linear, como a função sigmoide, tangente hiperbólica ou ReLU. Essa característica tem a capacidade de aproximar funções não lineares complexas, conforme o teorema da aproximação universal. (MOGHADAM, 2022).

Dentro do MATLAB é definido diferentes funções de ativação para as camadas da MLP. Nas camadas ocultas, são comumente utilizadas funções não lineares como *tansig* (tangente hiperbólica) ou *logsig* (sigmoide logística), enquanto na camada de saída, em problemas de regressão, é usual empregar a função linear *purelin*. Essa combinação favorece a modelagem de relações não lineares internas e a produção de saídas contínuas adequadas à estimação de parâmetros (MATHWORKS, 2024).

O MATLAB também disponibiliza uma interface gráfica que facilita a configuração e o treinamento de redes MLP, permitindo visualizar etapas como divisão dos dados, progresso do treinamento e análise de desempenho.

Figura 4 – Interface gráfica do MATLAB do treinamento de redes neurais




A tabela de progresso do treinamento contido na Figura 4 resume parâmetros relevantes, como o número de épocas executadas, o tempo total de processamento, a evolução da função de desempenho baseada no erro médio quadrático (MSE), o valor do gradiente e o parâmetro  $\mu$  associado ao algoritmo de Levenberg–Marquardt. O treinamento dentro do MATLAB se baseia em ajustar os pesos e bias da rede de forma a minimizar o erro entre a saída da rede e os valores desejados. Para redes MLP, a toolbox disponibiliza algoritmos de otimização baseados em retropropagação do erro, sendo o *Levenberg-Marquardt* (*trainlm*) um dos mais utilizados em problemas de regressão devido à sua rápida convergência para redes de pequeno e médio porte (MATHWORKS, 2024).

A toolbox do MATLAB necessita da divisão do conjunto de dados em subconjuntos de treinamento, validação e teste, o conjunto de treinamento é utilizado para ajustar os pesos, o conjunto de validação para monitorar o desempenho durante o treinamento e o conjunto de teste para avaliar o desempenho final do modelo. Configura-se manualmente as proporções desses subconjuntos por meio das propriedades *trainRatio*, *valRatio* e *testRatio*. Essa divisão permite adaptar o processo de treinamento às necessidades específicas do problema, como em aplicações com grande volume de dados ou com necessidade de validação rigorosa, como ocorre em estimação de parâmetros em sistemas elétricos de potência (MATHWORKS, 2024).

Após o treinamento, o MATLAB fornece diversas ferramentas para análise do desempenho da rede, como gráficos de erro médio quadrático (MSE), regressão entre valores estimados e reais, e análise de resíduos. Essas funcionalidades são essenciais para verificar a capacidade de generalização da rede MLP e evitar problemas como overfitting.

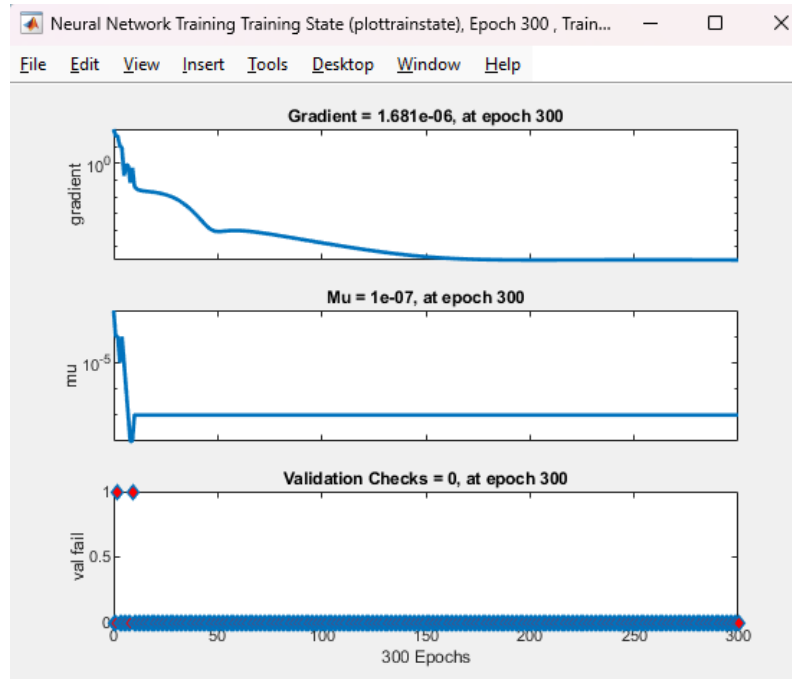
Figura 5: Desempenho do treinamento da rede neural



A Figura 5 apresenta a evolução do erro médio quadrático ao longo das épocas para os conjuntos de treinamento, validação e teste. Observa-se uma redução acentuada do erro nas primeiras iterações, indicando aprendizado rápido da rede neural, seguida por uma convergência gradual até valores extremamente baixos. O melhor desempenho de validação ocorre na época 300, com erro da ordem de  $10^{-10}$ , o que evidencia elevada capacidade de

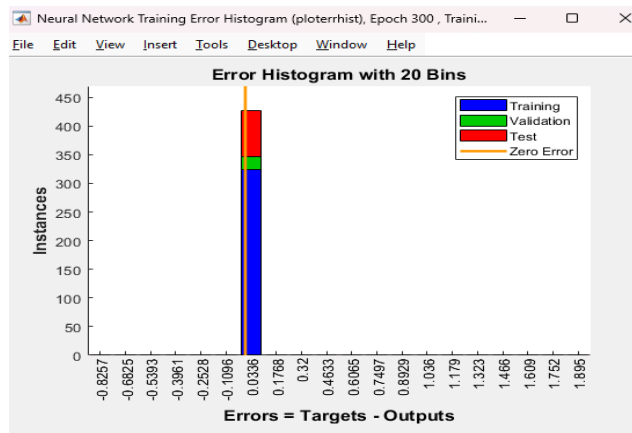
aproximação da MLP. A proximidade entre as curvas de treinamento e validação indica ausência de sobreajuste, enquanto a curva de teste, embora com erro superior, mantém-se estável, demonstrando boa capacidade de generalização do modelo.

Figura 6: Estado do treinamento da rede neural



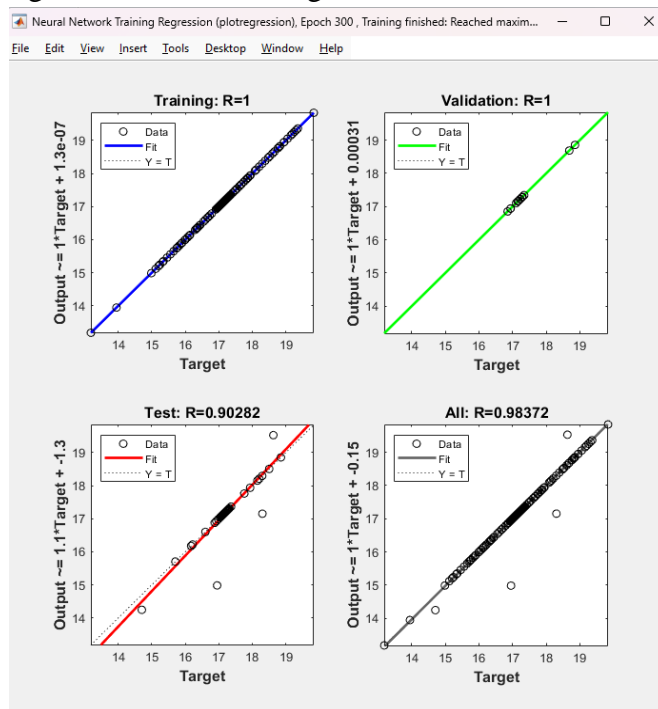
A Figura 6 é referente ao estado do treinamento da rede neural, e apresenta o comportamento interno do processo de aprendizagem ao longo das épocas. Observa-se que o valor do gradiente diminui progressivamente, indicando que os ajustes realizados nos pesos da rede tornam-se cada vez menores à medida que o modelo se aproxima de uma solução estável.

Figura 7: Histograma de erros da rede neural



A Figura 7 representa o histograma de erros da distribuição dos resíduos obtidos pela diferença entre os valores desejados (targets) e as saídas estimadas pela rede neural. Observa-se que a maior concentração de erros está fortemente agrupada em torno do erro zero, tanto para os dados de treinamento quanto para validação e teste. Esse comportamento indica elevada precisão do modelo e baixa dispersão dos erros, reforçando a capacidade da MLP em representar adequadamente a relação entre entradas e saídas do sistema analisado.

Figura 8: Gráficos de regressão da rede neural



A Figura 8 dos gráficos de regressão apresenta a comparação entre os valores fornecidos como referência e os valores estimados pela rede neural para os conjuntos de treinamento, validação e teste. Observa-se que os pontos se concentram próximos à linha de referência, o que indica boa correspondência entre as saídas geradas pela rede e os valores esperados.

### 3.2. METODOLOGIA EMPREGADA

A metodologia empregada utiliza a plataforma *Power System Analysis Toolbox* (PSAT), e técnicas de inteligência artificial, especificamente Redes Neurais Artificiais do tipo *Multilayer Perceptron* (MLP). Com o intuito de realizar a estimação dos coeficientes de amortecimento de modos eletromecânicos a partir de variáveis elétricas e estruturais do sistema, utilizando uma abordagem *model - based*, na qual a rede neural aprende o mapeamento entre grandezas observáveis e parâmetros dinâmicos do sistema. A metodologia foi estruturada em quatro etapas principais:

- Modelagem do sistema elétrico e análise modal no PSAT;
- Geração sistemática do banco de dados por meio de simulações;
- Treinamento, validação e teste da MLP no MATLAB;
- Avaliação do desempenho da rede neural por meio de métricas de erro e análise gráfica.

O PSAT é uma toolbox desenvolvida em ambiente MATLAB destinada à análise estática e dinâmica de sistemas elétricos de potência. A plataforma permite a realização de fluxo de potência, análise de estabilidade a pequenas perturbações, linearização do sistema em torno de um ponto de operação e extração da matriz de estados e de seus autovalores. Do ponto de vista matemático, o PSAT modela o sistema elétrico por meio de um conjunto de Equações Algébrico-Diferenciais (EADs) da forma:

$$\begin{cases} \dot{x} = f(x, y) \\ 0 = g(x, y) \end{cases} \quad (4)$$

Onde  $x$  representa as variáveis de estado dinâmicas (ex.: ângulos e velocidades dos geradores) e  $y$  representa as variáveis algébricas (ex.: tensões e ângulos das barras). Após a obtenção do ponto de operação via fluxo de potência, o sistema é linearizado, resultando no modelo de espaço de estados:

$$\Delta \dot{x} = A \Delta x \quad (5)$$

Em que  $A$  é a matriz de estados utilizada diretamente na análise modal.

A análise de estabilidade a pequenas perturbações é realizada a partir do cálculo dos autovalores da matriz de estados:

$$\lambda_i = \sigma_i + j\omega_i \quad (6)$$

Cada par complexo de autovalores está associado a um modo eletromecânico do sistema. A partir desses autovalores, são calculados os coeficientes de amortecimento dado por:

$$\zeta_i = \frac{-\sigma_i}{\sqrt{\sigma_i^2 + \omega_i^2}} \quad (7)$$

Este parâmetro indica a capacidade do sistema de amortecer oscilações eletromecânicas, sendo fundamental para a avaliação da estabilidade dinâmica. A frequência de oscilação associada a cada modo é obtida por:

$$f_i = \frac{\omega_i}{2\pi} \quad (8)$$

Essas grandezas são utilizadas tanto para a identificação dos modos críticos quanto para a construção do banco de dados supervisionado. A geração do banco de dados foi realizada por meio de simulações repetidas no PSAT, considerando uma ampla variedade de condições operativas. Em cada simulação:

1. O sistema é configurado com um conjunto específico de parâmetros;
2. Executa-se o fluxo de potência;
3. Realiza-se a análise modal;
4. Extraem-se as variáveis de entrada e as saídas desejadas.

Esse processo resulta em um banco de dados supervisionado, no qual as entradas representam o estado elétrico e estrutural do sistema e as saídas correspondem aos coeficientes de amortecimento dos modos eletromecânicos.

O vetor de entrada da rede neural é composto pelas seguintes grandezas: módulos das tensões nas barras; ângulos das tensões nas barras; potência ativa gerada nas barras PV; elementos da diagonal da matriz G; elementos da diagonal da matriz B; e elementos da diagonal da matriz de estados A.

$$x = [V; \theta; P_{PV}; \text{diag}(G); \text{diag}(B); \text{diag}(A) ] \quad (9)$$

O termo  $\text{diag}(G)$  representa os elementos da diagonal da matriz de condutância G, obtida da matriz admitância nodal do sistema elétrico, O termo  $\text{diag}(B)$  corresponde aos

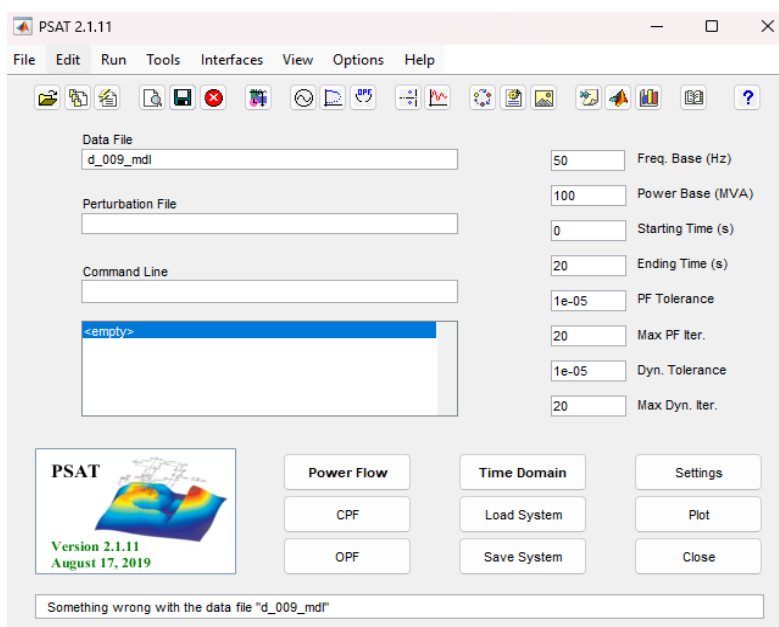
elementos da diagonal da matriz de susceptância B, já  $\text{diag}(A)$  representa os elementos da diagonal da matriz de estados A, proveniente da linearização do modelo dinâmico do sistema também derivada da matriz admitância nodal. Esse conjunto de variáveis permite capturar simultaneamente informações elétricas, topológicas e dinâmicas do sistema. As saídas da rede neural correspondem aos coeficientes de amortecimento de três modos eletromecânicos críticos, selecionados a partir da ordenação crescente dos valores de amortecimento. Assim, o vetor de saída é dado por:

$$y = [\zeta_1 \zeta_2 \zeta_3 \dots \zeta_i \dots \zeta_{Nm}] \quad (10)$$

Onde  $\zeta_i$  representa o amortecimento do i-ésimo modo selecionado. Na realização da simulação, foram considerados os seguintes cenários: contingências do tipo N-1 (remoção individual de linhas sem causar ilhamentos); variação da geração ativa; variação das tensões de referência dos geradores; variação das cargas; variação das reatâncias das linhas. Cada cenário gera uma nova amostra no banco de dados, resultando em um conjunto amplo de condições operativas.

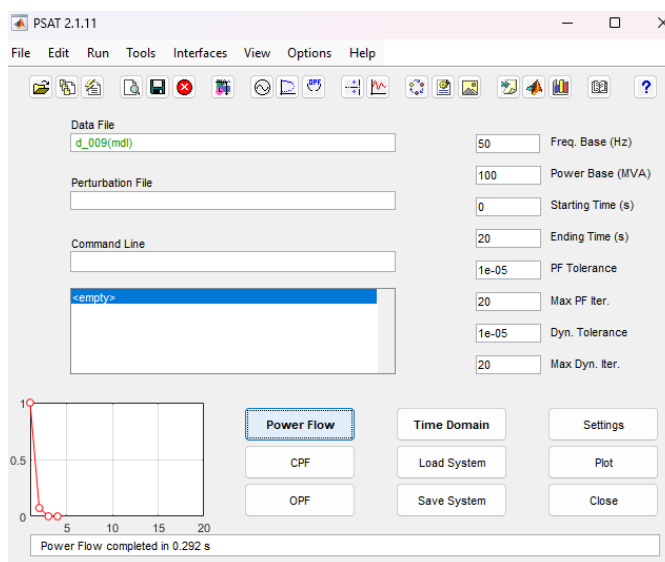
O PSAT é carregado no ambiente MATLAB por meio do comando de inicialização, o que habilita sua interface gráfica principal. A Figura 9 apresenta a janela inicial do PSAT, na qual o usuário pode importar sistemas elétricos, configurar parâmetros e selecionar os tipos de análise desejados.

Figura 9: Interface gráfica principal do PSAT



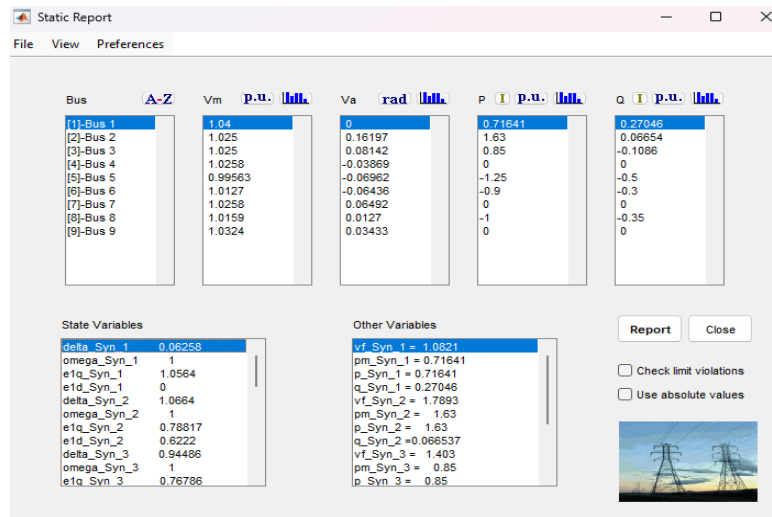
Após o carregamento do sistema elétrico, normalmente a partir de um arquivo de dados ou modelo previamente configurado, o primeiro passo consiste na execução do fluxo de carga, etapa essencial para garantir que o sistema esteja em regime permanente antes da análise dinâmica. Essa operação é realizada diretamente pela interface gráfica, por meio do menu de análises estáticas do PSAT.

Figura 10: Execução do fluxo de potência



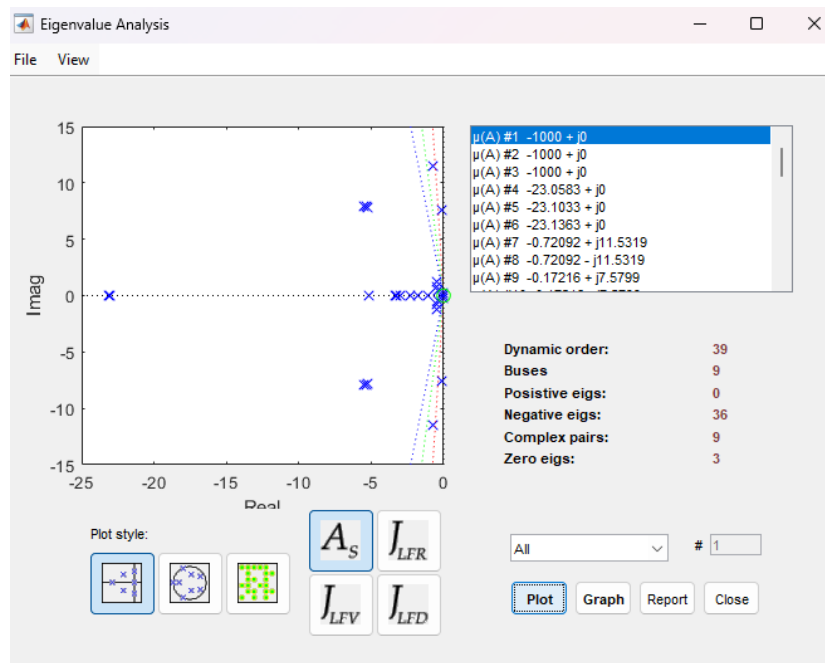
O botão Power Flow permite realizar o cálculo do fluxo de potência, etapa fundamental para garantir que o sistema esteja em regime permanente antes da análise dinâmica. O botão Time Domain é utilizado para iniciar a simulação no domínio do tempo, possibilitando a avaliação do comportamento dinâmico do sistema frente a perturbações. Além disso, são disponibilizadas opções adicionais, como CPF (*Continuation Power Flow*) e OPF (*Optimal Power Flow*), ampliando as possibilidades de análise do sistema.

Figura 11: Relatório de estatísticas do PSAT



A janela de *Static Report* do PSAT apresenta os principais resultados obtidos após a execução do fluxo de potência do sistema elétrico. São listadas as barras do sistema, acompanhadas de suas respectivas variáveis elétricas, como a magnitude da tensão em unidade por unidade (p.u.), o ângulo de tensão em radianos, além das potências ativa e reativas injetadas em cada barra. Essas informações permitem verificar se o sistema encontra-se operando dentro de limites aceitáveis.

Figura 12: Análise dos Autovalores



A Figura 12 apresenta graficamente os autovalores do sistema linearizado em torno do ponto de operação obtido pelo fluxo de potência. No plano complexo, os autovalores são representados por coordenadas com partes real e imaginária, permitindo uma visualização direta do comportamento dinâmico do sistema. A posição desses autovalores em relação ao eixo imaginário fornece informações fundamentais sobre a estabilidade, sendo que autovalores localizados no semiplano esquerdo indicam modos estáveis, enquanto autovalores com parte real positiva estão associados à instabilidade.

Além da interface gráfica, o PSAT permite a execução das simulações por meio de scripts em MATLAB (.m), abordagem adotada neste trabalho para automatizar os estudos e garantir reprodutibilidade dos resultados. Nesse método, a inicialização do PSAT, o carregamento do sistema e a execução das análises são realizados por comandos programados, eliminando a necessidade de intervenção manual a cada simulação.

O código estabelece as variáveis de controle das simulações, que representam as condições operativas do sistema elétrico. Esses parâmetros incluem os valores iniciais de potência ativa dos geradores, as cargas do sistema, as reatâncias das linhas de transmissão e as tensões de referência dos geradores. Tais variáveis permitem ajustar o ponto de operação do sistema antes da execução das análises, possibilitando a avaliação de diferentes cenários operativos sem a necessidade de intervenção manual.

A execução das análises é realizada por meio da chamada de uma função dedicada, responsável por integrar o PSAT ao processo computacional. Essa função executa primeiramente o fluxo de potência, em seguida é realizada a análise de estabilidade a pequenas perturbações, na qual o sistema é linearizado em torno do ponto de operação obtido.

A partir dessa linearização, são calculados os autovalores da matriz de estados, que descrevem o comportamento dinâmico do sistema frente a pequenas variações, os autovalores obtidos são utilizados para o cálculo dos coeficientes de amortecimento e das frequências dos modos oscilatórios, sendo identificados os modos eletromecânicos mais relevantes.

```

% Inicializa o PSAT
initpsat;
Settings.coi = 1;          % Usa o Centro de Inércia como referência de
ângulo
Settings.mva = 100;      % Define a base MVA do sistema

for j = 1:6
    runpsat('d_009_md1', 'data'); % Carrega o caso base do PSAT
    x = ones(6,1);           % Todas as linhas ligadas
    x(j) = 0;               % Remove a linha j (simulação N-1)

    [Entrada, saida] = executapsat(); % Executa fluxo de potência +
análise modal

    N(Nc) = Nc;             % Armazena o número da simulação
    C(:,Nc) = Entrada;     % Salva o vetor de 53 entradas
desta simulação
    S(:,Nc) = saida;       % Salva os 3 modos críticos
(amortecimento)
    Nc = Nc+1;            % Incrementa contador
end

```

Nesse trecho, o PSAT é inicializado e configurado para utilizar o centro de inércia como referência angular. Em seguida, o caso base do sistema é carregado automaticamente e são simuladas contingências do tipo N-1, nas quais cada linha de transmissão é retirada individualmente. Para cada cenário, a função *executapsat* é chamada, retornando os vetores de entrada e saída que são armazenados para posterior análise.

```

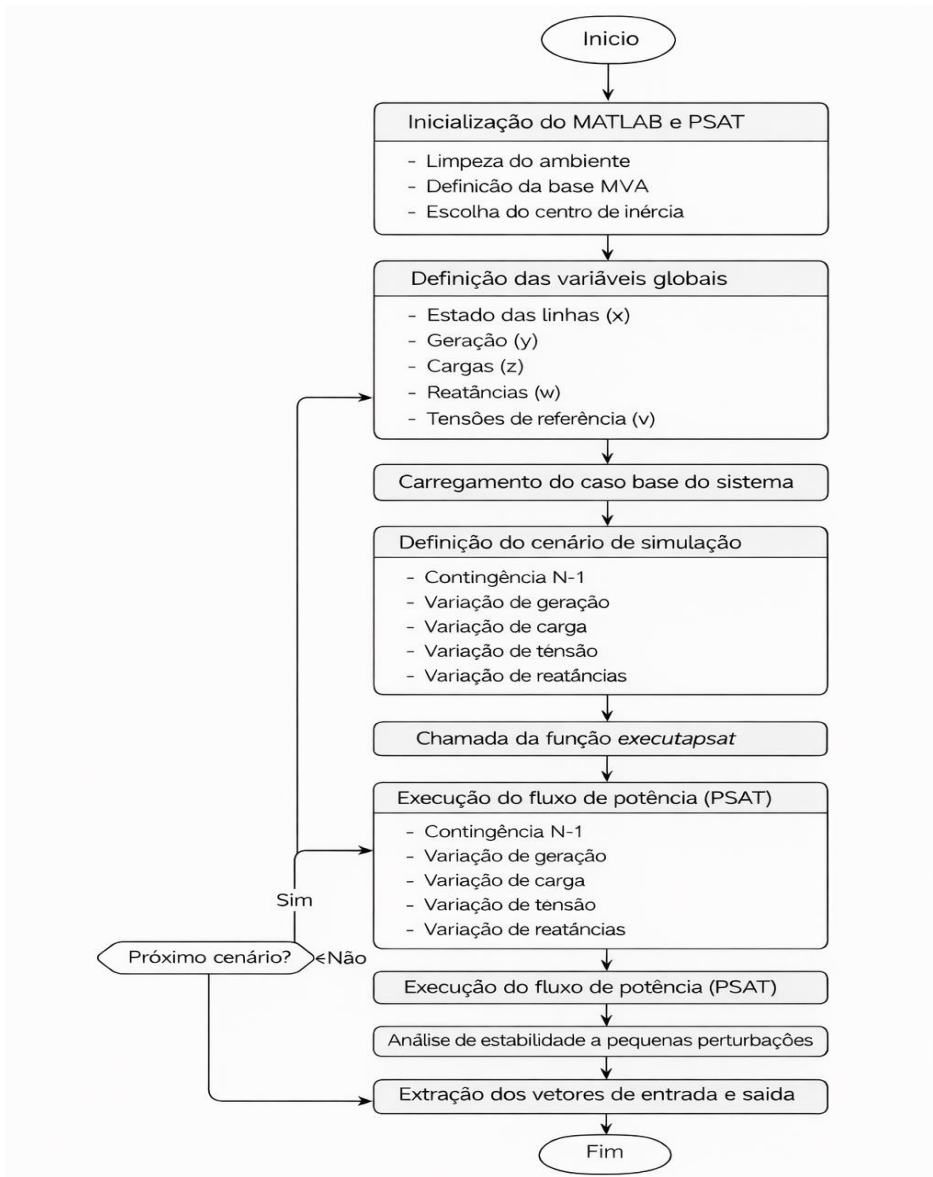
%Executa a análise de estabilidade
runpsat('sssa');
fm_abcd;
A = LA.a;
autovalor = eig(A);
diagA = diag(A);

%Cálculo do coeficiente de amortecimento
zeta = -real(autovalor) ./ sqrt(real(autovalor).^2 +
imag(autovalor).^2);

```

Nessa parte do algoritmo, é realizada a análise de estabilidade, na qual o sistema é linearizado em torno do ponto de operação. A matriz de estados é utilizada para o cálculo dos autovalores, a partir dos quais são obtidos os coeficientes de amortecimento e as frequências dos modos eletromecânicos. Esses resultados constituem as variáveis de saída do processo.

Figura 13: Fluxograma de execução do PSAT via arquivo (.m)



O fluxograma contido na Figura 13 representa o procedimento adotado para a execução automatizada do PSAT, evidenciando as principais etapas envolvidas na realização das simulações de estabilidade. São definidos os cenários de simulação, realizando contingências do tipo N-1 e variações nos níveis de geração, carga, tensões de referência e parâmetros das linhas de transmissão. Para cada cenário, são executados o fluxo de potência e a análise de estabilidade a pequenas perturbações, permitindo a extração dos vetores de entrada e saída associados às variáveis elétricas e aos modos eletromecânicos críticos..

A rede neural utilizada é do tipo Multilayer Perceptron (MLP), implementada por meio da Neural Network Toolbox do MATLAB. A arquitetura adotada possui:

- Três camadas ocultas;
- Dez neurônios em cada camada;
- Função de ativação tangente hiperbólica nas camadas ocultas;
- Função de ativação linear na camada de saída.

O conjunto de dados foi dividido aleatoriamente em:

- 75% para treinamento;
- 5% para validação;
- 20% para teste.

A avaliação do desempenho da MLP é realizada exclusivamente sobre o conjunto de teste (20%), utilizando as seguintes métricas:

Erro absoluto:

$$e_{abs} = |\hat{y} - y| \quad (11)$$

Erro percentual:

$$e_{\%} = \frac{|\hat{y} - y|}{|y|} \times 100\% \quad (12)$$


Com  $y$  sendo o valor real (valor observado no sistema), e  $\hat{y}$  sendo o valor estimado/predito pela rede neural. A metodologia realiza a união da modelagem matemática realizada no PSAT, com a flexibilidade computacional, proporcionada pelas redes neurais artificiais. Essa junção permite a estimação eficiente dos modos eletromecânicos, reduzindo a dependência de modelos completos e viabilizando aplicações em tempo real.

## CAPÍTULO 4

### 4.1. SISTEMA TESTE

O sistema utilizado na análise é o sistema teste IEEE de 9 barras, que foi escolhido por ser um dos modelos clássicos e mais utilizados em estudos de estabilidade e dinâmica de Sistemas Elétricos de Potência. Apesar de sua estrutura relativamente simples, esse sistema é capaz de representar adequadamente o comportamento dinâmico de geradores síncronos e apresentar modos eletromecânicos de oscilação, permitindo a análise de estabilidade a pequenas perturbações de forma eficiente. O sistema é constituído por nove barras interligadas por seis linhas de transmissão, três geradores síncronos e três barras de carga. Tipicamente, uma das barras é definida como barra slack, enquanto as demais barras associadas a geradores operam como barras do tipo PV, e as barras de carga são modeladas como barras do tipo PQ (ANWAR *et al.*, 2020).

Figura 14: Diagrama unifilar do sistema IEEE 9 barras



Fonte: (ANWAR *et al.*, 2020).

Tabela 1: Fluxo de carga do caso base do sistema IEEE de 9 barras

<i>Sr. No.</i>	<i>N° Barra.</i>	<i>Area</i>	<i>Tensão Nom. (KV)</i>	<i>p.u. (V)</i>	<i>Tensão (KV)</i>	<i>Angulo (Graus)</i>	<i>Carga (MW)</i>	<i>Carga (Mvar)</i>	<i>Ger (MW)</i>	<i>Ger (Mvar)</i>
1	Barra 1	1	16.50	1.04000	17.160	0.00	0	0	71.63	27.91
2	Barra 2	1	18.00	1.02500	18.450	9.35	0	0	163.00	4.90
3	Barra 3	1	13.80	1.02500	14.145	5.14	0	0	85.00	-11.45
4	Barra 4	1	230.00	1.02531	235.821	-2.22	0	0	0	0
5	Barra 5	I	230.00	0.99972	229.936	-3.68	125.00	50.00	0	0
6	Barra 6	1	230.00	1.01225	232.819	-3.57	90.00	30.00	0	0
7	Barra 7	1	230.00	1.02683	236.971	3.80	0	0	0	0
8	Barra 8	1	230.00	1.01727	133.971	12.4	100.00	100.00	0	0
9	Barra 9	1	230.00	1.03269	237.519	2.44	0	0	0	0

Fonte: (ANWAR *et al.*, 2020).

Tabela 2: Resultados do fluxo de potência sem faltas

<i>N°.</i>	<i>Da Barra</i>	<i>Para Barra</i>	<i>Dispositivo</i>	<i>MW de</i>	<i>MVar para</i>	<i>MVA from</i>	<i>MW perdas</i>	<i>MVar perdas</i>
1	8	9	<i>Linha</i>	-22	-23.6	32.1	0.1	-21
2	6	4	<i>Linha</i>	-28	-16.9	32.9	0.1	-16
3	7	8	<i>Linha</i>	78.8	-0.8	78.9	0.5	-12
4	9	6	<i>Linha</i>	63.3	-17.8	65.7	1.5	-31
5	5	4	<i>Linha</i>	-43	-39.6	58.5	0.3	-16
6	7	3	<i>Linha</i>	84.2	-10.1	84.8	2.2	-21
7	4	1	<i>Transformador</i>	-72	-24.8	75.8	0	3.15
8	2	7	<i>Transformador</i>	163	4.9	163	0	15.8
9	9	3	<i>Transformador</i>	-85	15.6	86.4	0	4.1

Fonte: (ANWAR *et al.*, 2020).

A modelagem elétrica das linhas de transmissão do sistema é realizada por meio do modelo  $\pi$  equivalente, que considera resistência série, reatância série e susceptância shunt.


Esse modelo é amplamente adotado em estudos de estabilidade, pois fornece uma representação adequada do comportamento elétrico das linhas em análises dinâmicas linearizadas, sendo compatível com métodos clássicos de fluxo de potência e análise modal.

A escolha do sistema IEEE-9 barras se baseia é devido o sistema apresentar interações dinâmicas entre máquinas síncronas capazes de gerar modos eletromecânicos oscilatórios, permitindo a aplicação direta de técnicas de análise modal e cálculo de autovalores. O sistema é extensivamente empregado em estudos de estabilidade transitória, alocação de dispositivos FACTS e análise de pequenas perturbações, o que permite comparação direta dos resultados obtidos neste trabalho com estudos consolidados. (AL-RUBAIY; AL-JUBOR, 2016).

## 4.2. RESULTADOS

Nessa seção serão discutidos os resultados referentes à estimação de modos eletromecânicos do sistema de 9 barras IEEE, por meio de uma abordagem baseada em redes neurais do tipo Perceptron Multicamadas (MLP). Os valores reais dos modos eletromecânicos foram obtidos a partir de simulações dinâmicas realizadas no psat, com os resultados contidos na imagem a seguir:

Figura 15: Resposta temporal dos três modos eletromecânicos estimados



A Figura 15 apresenta a resposta temporal associada aos três modos eletromecânicos do sistema, obtidos a partir das simulações dinâmicas realizadas no ambiente PSAT. Pode ser

observada a presença de três comportamentos distintos, associados a diferentes níveis de amplitude, amortecimento e complexidade dinâmica. O comportamento inicial das curvas é caracterizado por oscilações mais intensas, seguidas por uma transição gradual para um regime quase estacionário. Esse comportamento é típico de sistemas submetidos a pequenas perturbações, onde a resposta inicial é dominada pelos autovalores do sistema e, posteriormente, pelos modos mais amortecidos (KUNDUR, 1994).

O modo de menor amplitude apresenta um maior amortecimento, enquanto o modo de maior amplitude apresenta oscilações maiores, fisicamente mais críticos. Segundo Rogers (2000), modos com menor amortecimento são mais relevantes para estudos de estabilidade a pequenas perturbações, pois tendem a comprometer a segurança operativa do sistema. Quanto maior a variabilidade temporal e a amplitude do modo, maior é a complexidade associada ao aprendizado da rede neural artificial.

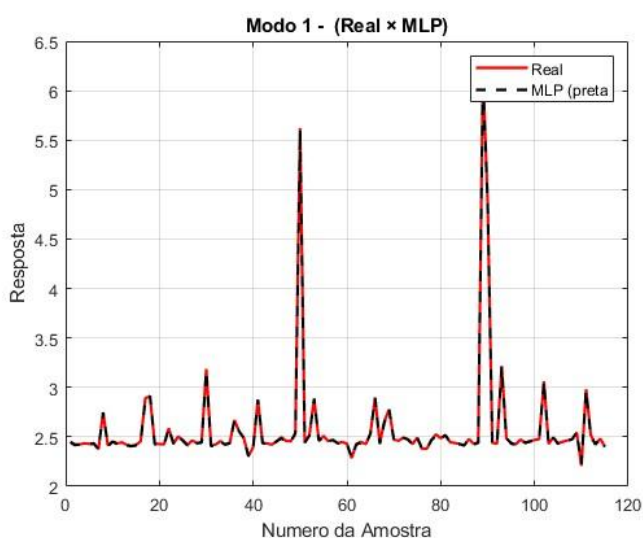
Com a obtenção dos modos eletromecânicos, com um total de conjunto de dados de 575 amostras, foi dividido aleatoriamente em três subconjuntos, 75% treino, utilizado para ajuste de pesos da rede MLP, 5% validação, utilizado para monitoramento do erro durante o treinamento e prevenção e 20% teste que é utilizado exclusivamente para avaliação final do desempenho. A distribuição aleatória dos índices garante que todos os regimes do sistema (transitório e permanente) estivessem representados no conjunto de treinamento. Essa estratégia é amplamente recomendada na literatura de aprendizado de máquina aplicada a sistemas dinâmicos, pois evita que a rede aprenda apenas padrões locais, o uso de um conjunto de teste independente, assegura que os resultados apresentados não uma memorização, mas sim uma generalização, um aspecto essencial para validação científica do modelo (BISHOP, 2006).

Os dados utilizados no treinamento foram alterados a fim de excitar distintos modos eletromecânicos, incluindo: (i) contingências do tipo N-1, simuladas por meio da retirada individual de cada uma das seis linhas de transmissão do sistema; (ii) variações na potência ativa gerada nas barras 2 e 3, com ajustes entre 50% e 150% dos valores nominais; (iii) variações nas tensões de referência dos reguladores de tensão dos dois geradores síncronos, entre 90% e 120% do valor base; (iv) variações nas cargas conectadas às barras 6, 8 e à barra adicional, com níveis entre 60% e 150% da carga nominal; e variações paramétricas nas reatâncias das seis linhas de transmissão, ajustadas entre 60% e 140% de seus valores

originais. Cada uma dessas modificações resultou em diferentes condições operativas e dinâmicas do sistema, a partir das quais foram extraídos os vetores de entrada e os modos eletromecânicos críticos utilizados no processo de treinamento.

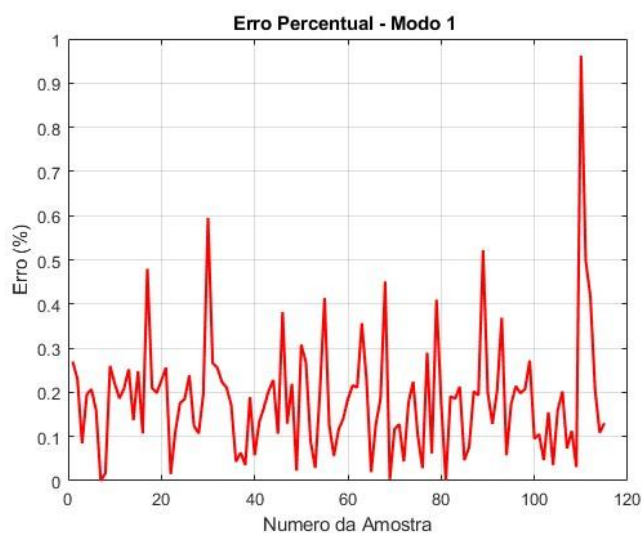
A Figura a seguir demonstra a estimação de modos eletromecânicos obtida pela rede MLP

Figura 16: Modo 1 (Real × MLP)



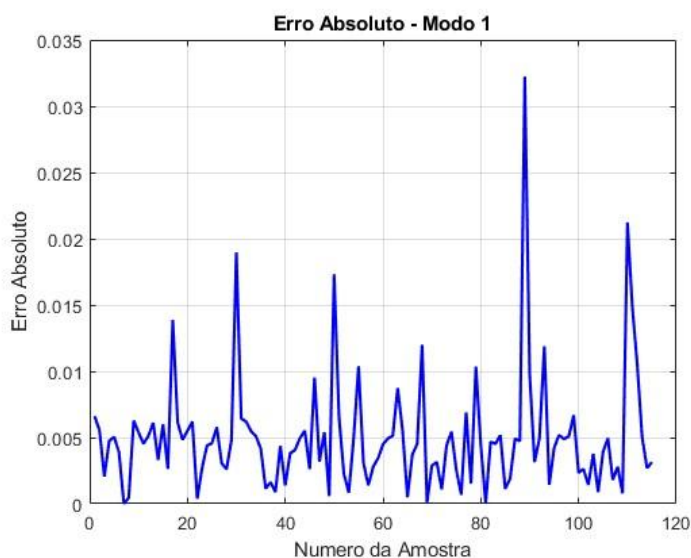
A Figura 16 apresenta a comparação entre o sinal real do modo 1 (modos locais) e o sinal estimado pela MLP, considerando apenas as amostras pertencentes ao conjunto de teste. Observa-se uma sobreposição praticamente completa entre as curvas, indicando que a rede neural conseguiu capturar com alta precisão a dinâmica desse modo. Fisicamente, o modo 1 apresenta menor amplitude e maior amortecimento, o que resulta em uma dinâmica mais suave e previsível. Segundo Kundur (1994), modos fortemente amortecidos possuem menor sensibilidade a perturbações, facilitando sua identificação por métodos baseados em dados.

Figura 17: Erro Percentual – Modo 1



O erro percentual contido na Figura 17 permanece majoritariamente abaixo de 0,3%, com picos isolados próximos de 1%. Esses picos estão associados a regiões de maior inclinação do sinal, sendo aceitáveis do ponto de vista prático. Esses picos estão associados a amostras específicas do conjunto de teste que correspondem a variações abruptas do sinal real, muitas vezes herdadas do regime transitório. Em métodos de identificação de sistemas, é esperado que regiões com maior gradiente do sinal apresentem erros localmente mais elevados, sem que isso represente falha estrutural do modelo.

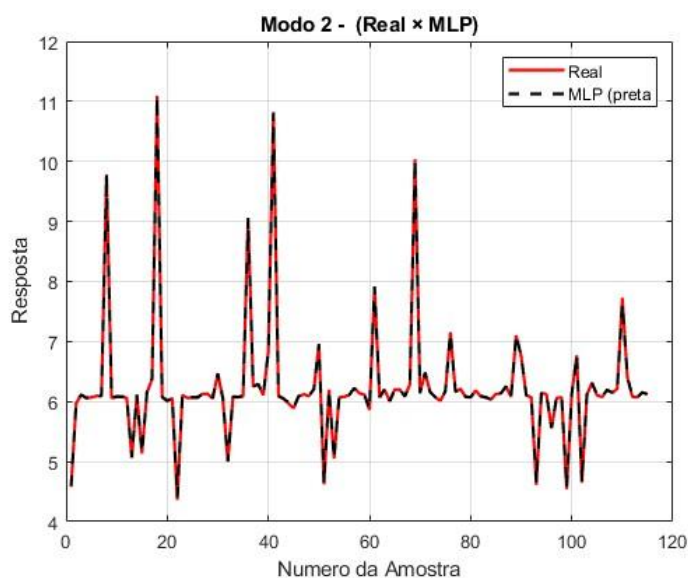
Figura 18: Erro Absoluto – Modo 1



A Figura 18 reforça essa análise ao mostrar que o erro absoluto permanece baixo ao longo de praticamente todo o conjunto de teste. A ausência de tendência crescente indica que não há viés acumulado, evidenciando estabilidade do modelo durante a generalização.

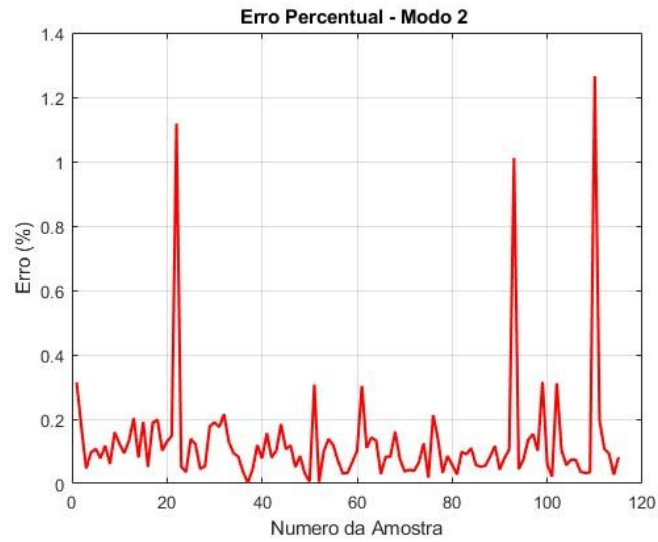
Partindo para análise da estimação do modo 2 (inter-área), a imagem a seguir demonstra o gráfico de comparação entre valores reais x MLP.

Figura 19: Modo 2 – (Real × MLP)




A Figura 19 apresenta a comparação entre os valores reais e estimados do modo 2. Observa-se novamente um excelente ajuste global, porém com discrepâncias ligeiramente maiores nos picos de maior amplitude. O modo 2 apresenta dinâmica intermediária, sendo mais complexo que o modo 1, A MLP foi capaz de acompanhar adequadamente essas variações, embora pequenas discrepâncias sejam observadas em picos extremos.. De acordo com Rogers (2000), modos com maior interação entre geradores tendem a apresentar maior variabilidade dinâmica, o que aumenta a dificuldade de estimação.

Figura 20: Erro Percentual - modo 2



Na Figura 20 observa-se que o erro percentual permanece, em média, abaixo de 0,2%, com picos isolados próximos de 1,2%. Esses picos ocorrem em amostras específicas do conjunto de teste, geralmente associadas a eventos de maior intensidade dinâmica. Esse comportamento é consistente com estudos measurement-based, que indicam que erros localizados durante eventos transitórios são aceitáveis, desde que o erro médio permaneça reduzido (ZHOU *et al.*, 2019).

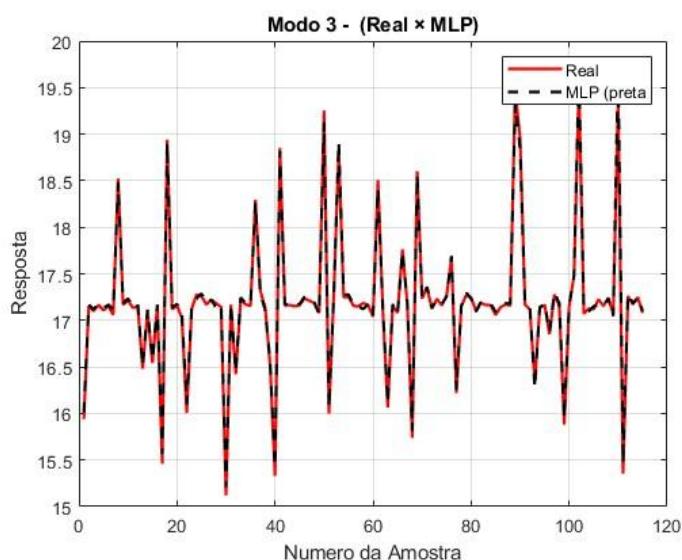
Figura 21 – Erro Absoluto – Modo 2



A Figura 21 evidencia que, apesar da presença de picos no erro absoluto, a distribuição desses erros é dispersa. Isso indica que a MLP consegue representar corretamente a dinâmica dominante do modo 2, falhando apenas em situações mais extremas, obtendo um desempenho global permanece satisfatório.


Partindo para análise do modo 3 (intra-planta), o gráfico demonstra a comparação entre os valores reais x MLP:

Figura 22: Modo 3 (Real x MLP)




A Figura 22 apresenta a comparação entre os valores reais e estimados do modo 3, considerado o modo mais crítico do sistema. Apesar da elevada sobreposição global, as discrepâncias são mais visíveis, especialmente em regiões de picos positivos e negativos. O modo 3 apresenta maior amplitude e menor amortecimento, sendo mais sensível a perturbações. Kundur (1994) destaca que modos fracamente amortecidos são intrinsicamente mais difíceis de estimar devido à sua alta sensibilidade dinâmica. Apesar disso, observa-se boa concordância entre os sinais real e estimado, evidenciando a capacidade da MLP em lidar com dinâmicas mais desafiadoras.

Figura 23: Erro Percentual – Modo 3



A Figura 23 mostra que o erro percentual do modo 3 apresenta maior dispersão, com valores que chegam a aproximadamente 1,8%. Ainda assim, a maior parte das amostras apresenta erro inferior a 0,5%, o que é considerado satisfatório para aplicações de monitoramento dinâmico.

Figura 24: Erro absoluto – modo 3



A Figura 24 demonstra que o erro absoluto do modo 3 é o mais elevado entre os três modos, com picos próximos de 0,35. Esse resultado reflete diretamente a maior complexidade dinâmica do modo e não compromete a validade do método.

Modos mais amortecidos apresentam melhor desempenho, enquanto modos mais críticos apresentam erros ligeiramente superiores. A correta separação dos dados em treino, validação e teste foi fundamental para garantir que a MLP aprendesse padrões gerais do sistema e não apenas particularidades locais. A presença de amostras do regime transitório no conjunto de treinamento foi determinante para o bom desempenho no teste.

## Capítulo 5

### 5.1.CONCLUSÕES

Este trabalho apresentou o desenvolvimento e a validação de uma metodologia baseada em Redes Neurais Artificiais do tipo *Multilayer Perceptron* (MLP) para a estimação de modos eletromecânicos em sistemas elétricos de potência. A motivação central esteve associada à necessidade de métodos rápidos, precisos e computacionalmente eficientes para a avaliação da estabilidade a pequenas perturbações. A metodologia proposta integrou modelagem matemática clássica, realizada por meio da análise modal no Power System Analysis Toolbox (PSAT), com utilização de RNAs implementadas no ambiente MATLAB.

A aplicação da metodologia ao sistema teste IEEE de 9 barras demonstrou que a MLP foi capaz de estimar com elevada precisão os coeficientes de amortecimento dos três modos eletromecânicos analisados. Os resultados demonstraram concordância entre os valores reais obtidos pela análise modal tradicional e os valores estimados pela rede neural, principalmente para os modos mais amortecidos.

A análise detalhada dos erros absoluto e percentual confirmou que o desempenho da rede neural está diretamente relacionado às características dinâmicas de cada modo. Modos com maior amortecimento apresentaram menor erro de estimação, enquanto modos fracamente amortecidos, mais sensíveis a perturbações, exibiram erros ligeiramente superiores, porém sem comprometer a validade da abordagem.

Os resultados obtidos indicam que a utilização de redes neurais MLP constitui uma alternativa eficiente aos métodos tradicionais de análise modal, especialmente em cenários onde a rapidez computacional é necessária. Como limitações do estudo, destaca-se o fato de a metodologia ter sido validada em um sistema teste de porte reduzido, o que, embora adequado para fins acadêmicos, não contempla todas as complexidades presentes em sistemas reais de grande escala. Além disso, o desempenho da rede neural está associado à qualidade do banco de dados utilizado no treinamento.

## 5.2. TRABALHOS FUTUROS

Como trabalhos futuros, sugere-se a aplicação da metodologia proposta a sistemas elétricos de grande porte e comparar os resultados encontrados com recentes metodologias que utilizam a previsão de modos eletromecânicos baseados em modelos e inteligência artificial.

## REFERÊNCIAS

- AL-RUBAIY, R. H.; AL-JUBOR, W. K. Study and Simulation of IEEE 9 Bus System with UPFC for Transient Stability Analysis. **Journal of Applied Sciences Research**, v. 12, n. 8, p. 36–48, 2016.
- ANWAR, N. *et al.* Transient Stability Analysis of the IEEE-9 Bus System under Multiple Contingencies. **Engineering, Technology & Applied Science Research**, v. 10, n. 4, 2020.
- BENTO, M. E. C. *et al.* A multistage algorithm for estimating electromechanical modes of power systems. **IFAC PapersOnLine**, 2024.
- BISHOP, C. M. Pattern Recognition and Machine Learning. **Springer**, 2006.
- CAÑIZARES, C. A. *et al.*, **Electric Energy Systems: Analysis and Operation**. Boca Raton: CRC Press, 2018.
- CAI, G. *et al.* Parameter identification of electromechanical oscillation mode in power systems driven by data: a quasi-real-time method based on randomized-DMD-multilayer artificial neural networks. **Frontiers in Energy Research**, 2022.
- CHEN, C.-S.; HSU, Y.-Y. Synchronous machine steady-state stability analysis using an artificial neural network. **IEEE Transactions on Power Systems**, 1991.
- COSTA FILHO, R. N. D., **Controle Robusto e Coordenado de Estabilizadores de Sistemas de Potência Utilizando Sinais Remotos com Vista à Estabilidade Angular dos Sistemas de Energia Elétrica. Tese (Doutorado)** - Programa de Pós-graduação em Engenharia de Eletricidade/ccet, Universidade Federal do Maranhão, São Luís, 2018.
- DORADO, R. S. A. *et al.* Time Series-Based Small-Signal Stability Assessment using Deep Learning. **Rensselaer Polytechnic Institute**, 2020.
- GIBBARD, M.; *et al.*, *Small-Signal Stability, Control and Dynamic Performance of Power Systems*. Adelaide: **University of Adelaide Press**, 2015.
- GUO, T.; WU, C.; CHEN, L. A measurement-based method for electromechanical mode identification using ambient data. **Electric Power Systems Research**, v. 180, p. 106–117, 2020.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Prentice Hall, 2009.
- IEEE POWER & ENERGY SOCIETY. IEEE 9-Bus System: Technical Note. **IEEE**, 2018.
- KHOKHAR, S.; MEMON, A. P.; KEERIO, M. U. Multilayer Perceptron Feedforward Neural Network Based Power System Stabilizer for Excitation Control System. **University of Research Journal of Engineering, Science & Technology**, v. 12, n. 2, jul./dez. 2013.
- KUNDUR, P. **Power System Stability and Control**. New York: McGraw-Hill, 1994.

LINARO, D. *et al.* Continuous estimation of power system inertia using convolutional neural networks. **Nature Communications**, 2023.

MATHWORKS. *Deep Learning Toolbox™ User's Guide*. Natick: **The MathWorks Inc.**, 2024. Disponível em: <https://www.mathworks.com/help/deeplearning/>. Acesso em: 15 dez. 2025.

MATHWORKS. Feedforward Neural Networks (MLP). Natick: **The MathWorks Inc.**, 2024. Disponível em: <https://www.mathworks.com/help/deeplearning/ref/feedforwardnet.html>. Acesso em: 15 dez. 2025.

MOJUMDER, M. R. H. **Power system stability analysis using neural network**. Dissertação (Mestrado) – Khulna University of Engineering & Technology, 2022.

MUHAMMED, A. O. *et al.* Deep Learning-Based Models for Predicting Poorly Damped Low-Frequency Modes of Oscillations. **IEEE Transactions on Power Systems**, 2024.

SAUER, P. W.; PAI, M. A., **Power System Dynamics and Stability**. Prentice Hall, 1998. SATHEESH, R. *et al.*, Identification of Oscillatory Modes in Power System Using Deep Learning Approach. **IEEE Access**, 10, 2023.

SAMAL, S. K.; SUBUDHI, B. *New signal subspace approach to estimate the inter-area oscillatory modes in power system using TLS-ESPRIT algorithm*. **IET Generation, Transmission & Distribution**, Londres, v. 13, n. 17, p. 1–9, 2019.

SHEN, Z.; DING, R. A., Novel Neural Network Approach for Power System Low Frequency Oscillation Mode Identification, 2019.

OLATUNJI, O. O. *et al.* Multilayer perceptron artificial neural network for the prediction of heating value of municipal solid waste. **AIMS Energy**, v. 7, n. 6, p. 944–956, 2019.

OSTOJIC, D. R.; HEYDT, G. T., Transient stability assessment by pattern recognition in the frequency domain, in **IEEE Transactions on Power Systems**, vol. 6, no. 1, p. 231-237, 1991.

PEPICIELLO, M.; VACCARO, A. Artificial Neural Network-based Small Signal Stability Analysis of Power Systems. **IEEE Madrid PowerTec**, 2021.

ROGERS, G. **Demystifying Power System Oscillations**. *IEEE Computer Applications in Power*, 1996.

ROGERS, G. **Power System Oscillations**. New York: Springer, 2000.

TRIPATHY, P.; SRIVASTAVA, S. C.; SINGH, S. N. A Modified TLS-ESPRIT-Based Method for Low-Frequency Mode Identification in Power Systems Utilizing Synchrophasor Measurements. **IEEE Transactions on Power Systems**, 2011.

WANG, Y. *et al.* Comparative study on estimation and identification of electromechanical oscillation parameters. **Journal of Physics:Conference Series**, 2024.

YUEFAN WANG *et al.* Comparative study on estimation and identification of electromechanical oscillation parameters. **Journal of Physics: Conference Series**, v. 2849, 2024.

ZHAO, S.; LOPARO, K. A. Forward and Backward Extended Prony (FBEP) Method for Power System Small-Signal Stability Analysis. **IEEE Transactions on Power Systems**, 2017.

ZHAO, Y. **Harmonic Estimation and Forecasting in Sparsely Monitored Uncertain Power Systems: Probabilistic and Machine Learning Approaches**, 2025.

ZHANG, Y. *et al.*, Data-driven modal analysis using neural networks. **IEEE Transactions on Smart Grid**, 2018.

ZHOU, N. *et al.* Measurement-based estimation of electromechanical modes. **IEEE Transactions on Power Systems**, 2016.

ZHOU, N. *et al.* Electromechanical Mode Estimation Using Synchrophasor Measurements: A Review. **IEEE Transactions on Power Systems**, v. 34, n. 1, p. 318–328, 2019.