

UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA  
ELÉTRICA

Luis Felipe Bianchi Carbonera

**REDE NEURAL NARX APLICADA AO AMORTECIMENTO DE  
OSCILAÇÕES DE POTÊNCIA**

Santa Maria, RS  
2020

**Luis Felipe Bianchi Carbonera**

**REDE NEURAL NARX APLICADA AO AMORTECIMENTO DE OSCILAÇÕES DE  
POTÊNCIA**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Maria (UFSM), como requisito parcial para a obtenção do título de **Doutor em Engenharia Elétrica**.

Orientador: Dr. Daniel Pinheiro Bernardon  
Coorientador: Felix Alberto Farret, PhD.

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

Carbonera, Luis Felipe Bianchi  
REDE NEURAL NARX APLICADA AO AMORTECIMENTO DE  
OSCILAÇÕES DE POTÊNCIA / Luis Felipe Bianchi Carbonera.-  
2020.  
106 p.; 30 cm

Orientador: Daniel Pinheiro Bernardon  
Coorientador: Felix Alberto Farret  
Tese (doutorado) - Universidade Federal de Santa  
Maria, Centro de Tecnologia, Programa de Pós-Graduação em  
Engenharia Elétrica, RS, 2020

1. Regulador de Tensão 2. Estabilizadores de Sistemas  
de Potência 3. Redes Neurais 4. Algoritmo Genético I.  
Pinheiro Bernardon, Daniel II. Farret, Felix Alberto  
III. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, LUIS FELIPE BIANCHI CARBONERA, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Tese) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

**Luis Felipe Bianchi Carbonera**

**REDE NEURAL NARX APLICADA AO AMORTECIMENTO DE OSCILAÇÕES DE POTÊNCIA**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica de Santa Maria (UFSM), como requisito parcial para a obtenção do título de **Doutor em Engenharia Elétrica**.

**Aprovado em 29 de outubro de 2020:**



**Daniel Pinheiro Bernardon, Dr. (UFSM)**  
(Presidente/Orientador)



**Felix Alberto Farret, PhD. (UFSM)**  
(Coorientador)



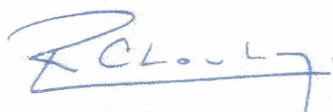
**Cristiane Cauduro Gastaldini, Dra. (Examinadora)**



**Gustavo Marchesan, Dr. (Examinador)**



**Mariana Resener, Dra. (Examinadora)**



**Roberto Chouhy Leborgne, Dr. (Examinador)**



## DEDICATÓRIA

Dedico este trabalho aos meus pais Roberto e Vidica e a minha amada Rosiele pelo amor e apoio em todos os momentos difíceis; a minha família, amigos e colegas de trabalho pelo companheirismo e amizade. Sem eles nada disso seria possível.



## **AGRADECIMENTOS**

*A minha esposa Rosiele que acompanhou todos os momentos, sempre esteve comigo comemorando as vitórias e apoiando nos momentos difíceis.*

*A minha família que sempre me incentivou, principalmente meus pais Roberto, Vidica e meu irmão Paulo, os quais me oportunizaram um ambiente de estudo e dedicação para almejar os meus objetivos.*

*A meu orientador Daniel Bernardon e ao professor Felix Farret por seus ensinamentos e por me mostrarem o caminho da pesquisa.*

*Aos meus amigos e colegas de profissão Douglas, Jordan, Alexandre e Gabriel pelas conversas, amizade e companheirismo.*

*A meu amigo engenheiro Jordan Nunes pelos ensinamentos e confiança em meu trabalho.*

*Aos professores Aécio, Luciano, Ederson e Adriano pelos questionamentos na qualificação que levaram este trabalho a evolução.*

*A faculdade SATC pelo total apoio e incentivo ao doutorado. Também aos amigos professores Jean, Breno, Vilson, Claudio e André.*

*Ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, pela oportunidade de realização de trabalhos em minha área de pesquisa.*

*A CAPES e CNPQ que financiaram este trabalho.*



*“A perseverança é a mãe da boa sorte.”*

*Miguel de Cervantes*

## RESUMO

### REDE NEURAL NARX APLICADA AO AMORTECIMENTO DE OSCILAÇÕES DE POTÊNCIA

AUTOR: Luis Felipe Bianchi Carbonera  
ORIENTADOR: Daniel Pinheiro Bernardon

A dinâmica dos sistemas de energia com elementos variáveis no tempo e não lineares torna muito complexo garantir uma operação estável, pois requisita um ajuste contínuo de cada elemento com a finalidade de se obter um desempenho adequado e eficiente. Grandes perturbações como curtos-circuitos, chaveamento de linhas, desconexão de gerador ou perda de grandes blocos de carga podem acarretar oscilações de potência. O controlador mais utilizado para contrapor a estas oscilações é o *Power System Stabilizer (PSS)*. As redes neurais artificiais (RNA) têm sido utilizadas como controle em muitas plantas dinâmicas não lineares. Para tal, esta tese explora a rede neural *nonlinear autoregressive exogenous model (NARX)* combinada com uma otimização multiobjetivo com a aplicação de algoritmos genéticos (AG) para amortecer as oscilações de potência. O modelo RNA é treinado utilizando um banco de dados determinado pelo AG para vários níveis de carga. Posteriormente, a própria rede pode alterar os parâmetros do estabilizador em tempo real. Uma nova técnica de geração de dados para treinamento da NARX é proposta, a qual necessita de poucos pontos de operação para que a rede neural reconheça os padrões do sistema. Este estudo é aplicado para ajustar o IEEE PSS4b em um sistema de quatro máquinas e duas áreas. Os resultados das simulações no estudo de caso demonstraram que o GA-NARX-PSS apresentou melhores efeitos no amortecimento das oscilações decorrentes das perturbações comparado com outras técnicas de ajuste de estabilizadores presentes na literatura. Observou-se que o GA-NARX-PSS amorteceu as oscilações provocadas por curto-circuitos com tempo de duração maiores que o suportado pelo PSS sintonizado tanto com otimização via AG como com o algoritmo *whale optimization algorithm (WOA)*.

Palavras-chave: Regulador de Tensão, Estabilizadores de Sistemas de Potência, Redes Neurais, Algoritmo Genético

# ABSTRACT

## THE NARX NEURAL NETWORK TO DAMP POWER SYSTEM OSCILLATIONS

AUTHOR: Luis Felipe Bianchi Carbonera

ADVISOR: Daniel Pinheiro Bernardon

*The dynamics of power systems with time-varying and non-linear elements is a complex matter since it involves continuous adjustments among every part for a suitable and efficient performance. Small disturbances in the load variation procedure also routinely occur. Consequently, the controller parameters must be adjusted to the variable conditions. The non-linear autoregressive model with exogenous input (NARX) neural network (NN) has been used in many non-linear dynamic systems. This paper explores the NARX combined with a multiobjective optimization by using genetic algorithms (GAs) to damp local and interarea oscillation modes. The NN model is trained by using a historical database determined by the GA for several load levels. Subsequently, the model can change the stabilizer parameters in real time after the learning phase. This study is used to tune a power system stabilizer (PSS) in a two-area four-machine system. This study is to adjust for the IEEE PSS4b in a system of four machines and two areas. The results of the simulations in the case study demonstrated that the GA-NARX-PSS had the best effects in dampening the oscillations resulting from the disturbances compared to other stabilizer adjustment techniques found in the literature. It was observed that the GA-NARX-PSS damped as oscillations caused by a short circuit with a longer duration than that supported by the PSS tuned with both AG optimization and the whale optimization algorithm (WOA).*

Keywords: Automatic Voltage Regulator, Power System Stabilizers, Neural Network, Genetic Algorithm.



## LISTA DE FIGURAS

Figura 1 – Diagrama de blocos da função de transferência do sistema mecânico do gerador síncrono.....	37
Figura 2 – Modelo do sistema de excitação .....	38
Figura 3 – Diagrama de blocos da função de transferência do regulador de velocidade da turbina.....	39
Figura 4 – Diagrama de blocos da função de transferência do servo motor e seu controlador .....	39
Figura 5 – Exemplo de Turbina a Vapor do tipo composta.....	39
Figura 6 – Partes da turbina a vapor.....	40
Figura 7 - Modelo da Turbina com o Regulador de Velocidade.....	41
Figura 8 - Modelo do Regulador de Velocidade .....	41
Figura 9 - Modelo do Regulador de Velocidade .....	42
Figura 10 - Representação conceitual do PSS4B .....	43
Figura 11 - Estabilizador de Potência PSS4B completo .....	44
Figura 12 – Representação do PSS4b com filtros avanço e atraso .....	44
Figura 13 – Metodologia Proposta .....	46
Figura 14 – Diagrama da otimização via AG .....	48
Figura 15 – Exemplo de função objetivo ITSE em bloco lógico .....	49
Figura 16 – Estrutura de uma rede neural com delays .....	51
Figura 17 – Arquiteturas paralela e série paralela da rede NARX .....	53
Figura 18 – Topologia da rede NARX proposta.....	53
Figura 19 – Diagrama lógico de design da rede neural .....	54
Figura 20 – Geração de dados para treinamento da rede NARX .....	55
Figura 21 – Topologia da rede NARX .....	57
Figura 22 – Sistema de duas áreas e quatro máquinas .....	58
Figura 23 – Sistema de duas áreas e quatro máquinas utilizado .....	60
Figura 24 – Distância média entre os indivíduos da melhor otimização encontrada com o AG (mutação uniforme 0,0105).....	62
Figura 25 – Função de seleção da melhor otimização encontrada com o AG (mutação uniforme 0,0105).....	62
Figura 26 – Histograma da função objetivo indivíduos da melhor otimização encontrada com o AG (mutação uniforme 0,0105).....	63
Figura 27 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms. ....	64
Figura 28 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms, por gerador. ....	64
Figura 29 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms, saída PSS e excitação.....	65
Figura 30 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 200 ms.....	65
Figura 31 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 200 ms, por gerador.....	66
Figura 32 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms, saída PSS e excitação.....	66
Figura 33 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 260 ms. ....	67

Figura 34 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 260 ms, resultado por geradores.....	68
Figura 35 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 260 ms.....	68
Figura 36 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 260 ms, por gerador.....	69
Figura 37 – Otimização do AG com as áreas interligadas após o distúrbio, 200 ms de curto-circuito.....	69
Figura 38 – Otimização do AG com as áreas interligadas após o distúrbio, 200 ms de curto-circuito.....	70
Figura 39 – Otimização do AG para 90% da carga, com tempo de curto-circuito de 200 ms.....	70
Figura 40 – Otimização do AG para 90% da carga, com tempo de curto-circuito de 200 ms, resultados por gerador.....	71
Figura 41 – Otimização do AG para 95% da carga, com tempo de curto-circuito de 200 ms.....	71
Figura 42 – Otimização do AG para 95% da carga com tempo de curto-circuito de 200 ms, resultado por gerador.....	72
Figura 43 – Melhor validação de desempenho do método bayesian Regulation backpropagation.....	73
Figura 44 – Resultado do Gradient, Mu e validação bayesian Regulation backpropagation.....	74
Figura 45 – AG-NARX-PSS carga nominal e tempo de curto-circuito 200 ms ..	74
Figura 46 – AG-NARX-PSS carga nominal e tempo de curto-circuito 200 ms, resultados por gerador .....	75
Figura 47 – AG-NARX-PSS carga pesada e tempo de curto-circuito 200 ms ...	75
Figura 48 – AG-NARX-PSS carga pesada e tempo de curto-circuito 200 ms, por gerador.....	76
Figura 49 – AG-NARX-PSS carga leve e tempo de curto-circuito 200 ms.....	76
Figura 50 – AG-NARX-PSS carga leve e tempo de curto-circuito 200 ms, por gerador.....	77
Figura 51 – AG-NARX-PSS carga nominal e tempo de curto-circuito 100 ms ..	77
Figura 52 – AG-NARX-PSS carga nominal e tempo de curto-circuito 100 ms, por gerador.....	78
Figura 53 – Saída do AG-NARX-PSS para o $G_1$ , carga nominal e tempo de curto-circuito 200 ms.....	78
Figura 54 – Histórico da busca com o WOA.....	79
Figura 55 – Comparação entre AG-NARX-PSS, WOA e AG com parâmetros fixo com carga leve e tempo de curto-circuito em 200 ms .....	80
Figura 56 – Comparação entre AG-NARX-PSS, WOA e AG com parâmetros fixo com carga pesada e tempo de curto-circuito em 200 ms .....	80
Figura 57 – Comparação entre AG-NARX-PSS, WOA e AG com parâmetros fixo com carga nominal e tempo de curto-circuito em 400 ms .....	81
Figura 58 – Estrutura Básica de um AG .....	94
Figura 59 – Estrutura de um neurônio humano. ....	96
Figura 60 – Modelo não-linear de um neurônio .....	97
Figura 61 – Gráfico da função de ativação sigmoide .....	98
Figura 62 – Método de caça das baleias .....	105
Figura 63 – Rede de bolhas em forma de espiral.....	106



## LISTA DE TABELAS

Tabela 1 – Cenários de teste (em MW e MVAR) .....	59
Tabela 2 – Parâmetros geradores do sistema base .....	60
Tabela 3 – Resultados do AG com sistema com carga nominal e diferentes tipos de funções objetivos.....	61
Tabela 4 – Melhores resultados com o AG com modificação dos parâmetros de mutação .....	61
Tabela 5 – Ganhos utilizados para o PSS4b .....	63
Tabela 6 – Resultado das funções de treinamento para a NARX.....	73
Tabela 7 – Relação entre o processo de evolução natural e um problema computacional.....	92



## LISTA DE ABREVIATURAS E SIGLAS

AG	–	Algoritmo Genético
AVR	–	<i>Automatic Voltage Regulator</i>
FACTS	–	<i>Flexible AC Transmission Systems</i>
IEEE	–	<i>Institute of Electrical and Electronic Engineers</i>
IAE	–	<i>The Integral of Absolute Error</i>
ISE	–	<i>The Integral of Squared Error</i>
ITAE	–	<i>The Integral of Time Multiply Absolute Error</i>
ITSE	–	<i>The Integral of Time Multiply Squared Error</i>
LTs	–	Linhas de Transmissão
MB-PSS	–	<i>Multiband Power System Stabilizer</i>
MOO	–	otimização multiobjetivo
NARX	–	a nonlinear autoregressive exogenous model
ONS	–	Operador Nacional do Sistema Elétrico
PSS	–	<i>Power System Stabilizers</i>
RNA	–	Redes Neurais Artificiais
TFL	–	transformações fracionais lineares
TDL	–	<i>tapped delay line</i>
WOA	–	<i>Whale Optimization Algoritim</i>



## LISTA DE SÍMBOLOS

$T_f$	Constante de tempo do campo
$T_e$	Constante de tempo
$T_{sm}$	Relé de velocidade
$\omega_{ref}$	Referência de velocidade
$\Delta\omega$	Desvio de velocidade
$\delta$	Ângulo do rotor
$K_l$	Ganho PSS4b para frequência baixa
$K_i$	Ganho PSS4b para frequência intermediária
$K_h$	Ganho PSS4b para frequência alta
$K_p$	Ganho proporcional
$K_e$	Constante proporcional
$K_a$	Ganho proporcional
$R_p$	Estatismo permanente
$V_{stab}$	Sinal de saída do PSS
$T_a$	Constante de tempo
$T_m$	Torque mecânico
$T_c$	Constante de tempo do avanço atraso
$T_b$	Constante de tempo do avanço atraso
$V_{f0}$	Tensão de campo inicial
$V_{ref}$	Referência da tensão de campo
$P_{ref}$	Referência da potência elétrica
$K_d$	Coefficiente de amortecimento
$f_l$	Frequência PSS4b para frequência baixa
$f_i$	Frequência PSS4b para frequência intermediária
$f_h$	Frequência PSS4b para frequência alta
$V_t$	Tensão Terminal
$d_{theta}$	Ângulo de carga
$P_m$	Potência mecânica
$Tr_{5-2}$	Constantes de tempo da turbina em segundos
$e(k+1)$	Entrada da rede neural
$s(k+1)$	Saída da rede neural

## SUMÁRIO

1	Introdução	23
1.1	Considerações gerais	23
1.2	Motivação	24
1.3	Objetivos	25
1.3.1	Objetivos Específicos	25
1.4	Contribuições	25
1.5	Organização da tese	26
2	Revisão da literatura	27
2.1	Métodos para parametrização do PSS	27
2.1.1	Gera e testa	28
2.1.2	Comparação entre grandezas	28
2.1.3	Compensação de Fase	29
2.1.4	Controle Robusto	29
2.1.5	Métodos Computacionais com parâmetros fixos	29
2.1.6	Métodos Computacionais com parâmetros dinâmicos	30
2.1.6.1	Controle Adaptativo	31
2.1.6.2	Redes Neurais	31
2.2	Comparativo entre métodos para parametrização do PSS	33
2.3	PSS no contexto das Redes Elétricas Inteligentes	33
2.4	Considerações Finais	35
3	Modelagem do Sistema	36
3.1	Formulação do Problema de Estabilidade	36
3.2	A excitação do gerador síncrono	37
3.3	Modelo da turbina e regulador de velocidade	38
3.4	IEEE PSS4B	42
3.5	Considerações Finais	45
4	Metodologia proposta	46
4.1	Introdução	46
4.1.1	Metodologia para a simulação off-line	47
4.1.2	Metodologia simulação on-line	47
4.2	Algoritmo Genético (AG)	47
4.2.1	Otimização com o AG proposto	47
4.2.2	Função multiobjetivo proposta	49
4.3	Modelo de rede neural NARX	51
4.3.1	Proposta de arquitetura para rede NARX	52

4.4	Geração de dados para Treinamento	55
4.5	Considerações Finais	57
5	Resultados Obtidos	58
5.1	Sistema base	58
5.2	Otimizações via Algoritmo Genético	60
5.3	Resultados AG-NARX-PSS	72
5.4	Otimizações via WOA	79
5.5	Comparação da metodologia	79
5.6	Considerações Finais	81
6	Conclusões	82
6.1	Trabalhos Futuros	83
6.2	Publicações	83
7	Referências Bibliográficas	85
	Apêndice A – Algoritmos genéticos	92
	Apêndice B – Redes neurais artificiais	95
	Apêndice C – Script NARX Matlab	100
	Apêndice D – Função custo global para o AG	103
	Apêndice E – Algoritmo de otimização de baleias	104



## 1 INTRODUÇÃO

### 1.1 CONSIDERAÇÕES GERAIS

A dinâmica dos sistemas de energia com elementos variáveis no tempo e não lineares torna muito complexo garantir uma operação estável, pois requisita um ajuste contínuo de cada elemento para obter-se um desempenho adequado e eficiente. Grandes perturbações como curtos-circuitos, chaveamento de linhas, desconexão de gerador e perda de grandes blocos de carga podem acarretar oscilações de potência. As oscilações de potência de baixa frequência são geralmente observadas em sistemas cujas linhas elétricas fazem parte de conexões fracas, linhas mal dimensionadas ou cargas pesadas demais nos terminais da rede (MENCO, 2018).

As oscilações de potência podem causar perda de sincronismo entre a geração e a carga, resultando em um blecaute. Outra característica das oscilações de pequena magnitude ou de baixa frequência é que elas podem durar longos períodos e limitar a transmissão de energia elétrica. O principal controlador utilizado para se contrapor a este fenômeno é o *Power System Stabilizer* (PSS). Os PSSs equipam os *Automatic Voltage Regulator* (AVR) dos geradores síncronos para amortecer estas oscilações, controlando a excitação do gerador. Normalmente, a saída do PSS é adicionada à função de transferência de um AVR que pode ser considerado como um bloco adicional no controle de excitação dos geradores. Dessa forma, espera-se que um PSS produza uma saída em contra fase ao sinal a ser amortecido. O sinal deve estar em fase com os desvios de velocidade do rotor do gerador, suavizando diferentes tipos de oscilação (IEEE, 2005).

Conforme a magnitude da reatância da conexão, geradores no mesmo sistema de potência podem oscilar na frequência de 2 a 3 Hz. Esta frequência oscilante é chamada de intraunidade. O ponto interessante sobre esse tipo de oscilação é que o restante do sistema não é afetado. Particularmente no modo local, o gerador oscila com o restante do sistema em uma frequência entre 1 e 2 Hz. Um modo de oscilação entre áreas pode ocorrer quando máquinas de uma região oscilam junto com uma máquina de outra região a uma frequência de 1 Hz ou menos. Também, existem oscilações de torcionais que ocorrem entre vários elementos rotativos da unidade geradora, como o rotor do gerador, o

excitador do rotor, os eixos e as turbinas. As frequências das oscilações torcionais geralmente chegam a 4 Hz. Por esses motivos, a parametrização correta de um PSS não deve interferir nessas frequências oscilantes naturais (SHAKARAMI; DAVOUDKHANI, 2016).

## 1.2 MOTIVAÇÃO

O PSS deve ser cuidadosamente ajustado para aumentar, com segurança, os limites operacionais e a estabilidade do sistema elétrico. Para se obter um bom desempenho, o PSS deve, primeiramente, detectar o tipo de oscilação e, em seguida, garantir um modo de amortecimento seguro das oscilações garantindo, assim, a estabilidade do sistema. A parametrização do PSS é um tópico de grande interesse para os comissionadores e fabricantes. O comissionamento do controlador deve ser finalizado o mais rápido possível e endossar uma operação adequada em relação às diferentes condições de operação do sistema elétrico (SAHU et al., 2019).

Em 2009, aconteceu uma perturbação com oscilação de potência no Brasil. Um problema, localizado em uma das Linhas de Transmissão (LTs) que interligam a usina de Itaipu à região Sudeste do Brasil desencadeou uma série de desligamentos automáticos. Neste evento, como resultado da oscilação de potência gerada, verificou-se que a região Sul operou com uma frequência de 63,6 Hz por alguns instantes, enquanto a região Norte e Centro-Oeste com 58,3 Hz (OPERADOR NACIONAL DO SISTEMA ELÉTRICO, 2009).

A maioria das técnicas empregadas, atualmente, nas unidades geradoras não são eficientes para todas as faixas de operação. Isto encorajou o desenvolvimento deste trabalho tendo como principal objetivo a aplicação da rede neural NARX para amortecimento das oscilações.

Ressalta-se que, apesar de haver trabalhos sobre o tema, eles não abordam a rede NARX no problema do estabilizador a qual apresenta algumas vantagens em relação as outras topologias. Nenhum trabalho utiliza estabilizadores consolidados por normativas como o IEEE PSS2b e IEEE PSS4b fazendo com que sua aplicação seja dificultada aos fabricantes de turbinas e geradores. Outros trabalhos (conforme Quadro 1) utilizam como validação apenas sistemas de um gerador na barra infinita deixando dúvidas sobre a



capacidade dos controladores. Por fim, nesta tese uma nova técnica de geração de dados para treinamento da NARX é proposta, a qual necessita de apenas quatro pontos de operação para que a rede neural reconheça os padrões do sistema.

### 1.3 OBJETIVOS

Esta tese tem como principal objetivo propor uma metodologia para amortecimento de oscilações de potência em regime transitório através de um sistema híbrido que combina uma rede neural NARX com a otimização dos parâmetros estabilizadores de potência IEEE PSS4b via Algoritmo Genético (AG).

#### 1.3.1 Objetivos Específicos

Como objetivos específicos esta tese busca:

- a) Otimização multiobjetivo dos ganhos do PSS via AG;
- b) Desenvolvimento de um controlador neural NARX com os ganhos otimizados via AG para várias condições de carga do sistema;
- c) Proposta de nova técnica para geração de dados de treinamento da rede neural.
- d) Comparação da metodologia desenvolvida com outras metodologias para comprovação da eficácia do método proposto.

### 1.4 CONTRIBUIÇÕES

Esta tese de doutorado pretende contribuir de forma inovadora com:

- Proposta de rede neural NARX para controle em tempo real dos parâmetros do PSS4b em um sistema multimáquinas baseado na criação de um banco de dados de aprendizado obtido a partir da otimização do AG em uma ampla faixa de condições de carga;
- Análise de sensibilidade para um NARX com diferentes números de *delays*, neurônios, camadas ocultas, entradas e comparações entre funções de treinamento da rede neural;

- Proposta de nova metodologia para treinamento da rede neural que pode ser aplicada a qualquer outro controlador e planta.

## 1.5 ORGANIZAÇÃO DA TESE

Esta tese é dividida em seis capítulos descritos a seguir:

- O capítulo 1 foi dedicado a introdução do trabalho com a inclusão dos objetivos, motivações e contribuição inovadoras.
- O capítulo 2 introduz a revisão bibliográfica com o intuito de destacar as contribuições inovadoras deste trabalho, em que são mostradas as principais diferenças e melhorias em comparação com a bibliografia.
- O capítulo 3 apresenta a formulação do problema de estabilidade, sistema de excitação do gerador síncrono, modelo da turbina e regulador de velocidade e o estabilizador a ser utilizado IEEE PSS4B.
- O capítulo 4 apresenta a metodologia proposta AG-NARX-PSS para amortecimento de oscilações de potência; primeiramente uma otimização via AG com função multiobjetivos é descrita, posteriormente as redes neurais, rede neural NARX, e, finalmente, é exibido o sistema base utilizado.
- O capítulo 5 consiste nos resultados obtidos de simulação via AG e comparados com os resultados do método de alocação de polos na primeira etapa e, na segunda, são apresentados os resultados do AG-NARX-PSS e uma comparação com as outras metodologias. O algoritmo de otimização das baleias (WOA) é apresentado como forma de comparação com a metodologia proposta
- O capítulo 6 apresenta as considerações finais e conclusões da tese, assim como as publicações obtidas no período de doutorado.

Por fim, são apresentadas as referências bibliográficas e apêndices.

## 2 REVISÃO DA LITERATURA

Este capítulo tem por objetivo apresentar uma revisão bibliográfica sobre os principais métodos utilizados para a parametrização do PSS, bem como, apresentar as inovações da metodologia proposta.

### 2.1 MÉTODOS PARA PARAMETRIZAÇÃO DO PSS

Existem exigências conflitantes para o amortecimento ideal de oscilações de tensão e frequência em sistemas de potência elétrica, tanto em modo local quanto em interárea. Ambos necessitam garantir a estabilidade de potência em condições de pequenos sinais e de transitórios. Isto conduz a diferentes abordagens de controladores e de parametrização dos estabilizadores. A grande diversidade das abordagens é explicada pela dificuldade de se satisfazer as metas de projeto, além de que cada método possui vantagens e desvantagens. Este é o ponto crucial do problema do amortecimento das oscilações de baixa frequência com os estabilizadores de sistemas de potência e é o foco principal desta tese.

Os principais métodos de parametrização dos PSSs com parâmetros fixos são:

- **Gera e Testa:** método baseado apenas na experiência do comissionador.
- **Comparação entre Grandezas:** compara a defasagem entre diferentes grandezas após a introdução proposital de pequenas perturbações.
- **Compensação de Fase:** busca compensar as defasagens entre a entrada de referência da tensão do RT e o torque elétrico.
- **Controle Robusto:** a teoria de controle ótimo fornece técnicas para incorporar a otimização de critérios de desempenho, além de garantir a estabilidade.
- **Métodos Computacionais:** procura ajustes ótimos de um ou vários PSSs a partir da modelagem do sistema.

Os principais métodos de parametrização dos PSSs com parâmetros dinâmicos são:

- **Redes Neurais Artificiais (RNA):** O aprendizado de máquina baseado em Inteligência Artificial.
- **Filtros Adaptativos:** ação de controle de sistemas capazes de modificar seus próprios parâmetros em resposta a alterações verificadas em algum módulo que esteja sendo monitorado.

Nos próximos subitens são explanados mais detalhadamente os métodos de parametrização do PSS e, por fim, é feito um comparativo entre métodos para parametrização do PSS.

### 2.1.1 Gera e testa

O método baseado em gera e testa depende de uma série de fatores para poder ser realizado de forma satisfatória. São realizados ensaios durante o comissionamento em que se parte de ajustes de PSS em usinas semelhantes (MOTA, 2010), onde posteriormente:

- Provocam-se distúrbios na referência de tensão;
- Verificam-se as oscilações com e sem o PSS;
- Realizam-se ajustes finos nos parâmetros dos blocos de avanço e atraso;
- Comparam-se as respostas com diferentes ajustes do PSS.

### 2.1.2 Comparação entre grandezas

O ajuste que utiliza comparações entre grandezas pode ser realizado de diferentes formas, contrapondo sinais de diferentes grandezas durante pequenos distúrbios provocados de forma proposital:

- Constata-se que as oscilações de tensão estão em fase com as oscilações de frequência devido à ação do PSS;
- Constata-se a saída do PSS com a potência ativa para amortecer oscilações locais que devem estar em contra fase para o amortecimento máximo, assim sugerido por Gu, Smulders e Mushens (2000).

### 2.1.3 Compensação de Fase

O método de compensação de fase busca gerar um torque elétrico em fase com as oscilações de velocidade do rotor. Para alcançar este objetivo é compensada a defasagem ocorrida entre a referência de tensão do AVR ( $\Delta e_{t_{ref}}$ ) e o torque elétrico ( $\Delta T_e$ ). A dificuldade deste método consiste em estabelecer a relação  $\Delta T_e/\Delta e_{t_{ref}}$  o que em campo não é possível. Uma solução apresentada na literatura técnica é fazer aproximações a partir do modelo linearizado (MOTA, 2010).

### 2.1.4 Controle Robusto

A teoria do controle robusto que começou no final dos anos 70 visa garantir a estabilidade e o atendimento ótimo de critérios de desempenho. As ações de controle por realimentação devem realizar estas tarefas mesmo com incertezas no modelo da planta, na dinâmica e na operação dos sensores e atuadores (ZUBEN, 2003).

A teoria do controle robusto requisita um modelo linearizado da planta, uma representação por espaço de estados e a descrição das incertezas a serem consideradas no projeto. Algumas das técnicas utilizadas conforme (ZUBEN, 2003) são:

- Técnicas de análise para determinação da robustez de um controlador, como análise de valores singulares, análise- $\mu$ , modelagem via transformações fracionais lineares (TFL).
- Técnicas de síntese: geração de leis de controle lineares, não-adaptativas (fixas) e robustas. Exemplos: síntese  $H_\infty$ , síntese  $H_2/H_\infty$ , problema linear quadrático com considerações de robustez, otimização numérica.

Alguns exemplos de aplicações do controle robusto para o amortecimento de oscilações podem ser encontrados em (KISHOR et al., 2014; SANTRA; SUBRATA, 2016; ISBEIH et al., 2019). Estas aplicações foram comparadas com as outras metodologias no Quadro 1.

### 2.1.5 Métodos Computacionais com parâmetros fixos

Mais recentemente, os métodos computacionais estão sendo largamente utilizados em aplicações de engenharia. Contando-se com a evolução dos computadores e suas ferramentas, é possível utilizá-los no planejamento, projeto, operação e controle de um sistema de potência. Em alguns casos, os métodos computacionais são utilizados na parametrização em tempo real de estabilizadores de potência. Estes métodos exigem muitos dados para simulação, porém uma vez levantados, é possível explorar o máximo dos estabilizadores. Inúmeros algoritmos de otimização são utilizados.

Alguns exemplos de algoritmos de otimização utilizados em PSSs: AG (FORTES et al., 2016) e (SUNDARESWARAN; RAZIA BEGUM, 2004), Otimização de Acasalamento de Abelhas (MOHAMMADI; GHADIMI, 2014), Técnicas de enxame e Taguchi (SHAYEGHI et al., 2013), Enxame de partículas (WANG et al., 2018) e Algoritmo de otimização de baleias (WOA) encontrado em (SAHU et al., 2019), (BUTTI et al., 2020) e (MIRJALILI; LEWIS, 2016), Otimização do Lobo Cinza (SHAKARAMI; DAVOUDKHANI, 2016). Os AGs diferem dos métodos convencionais de otimização de busca devido à sua melhor solução em vários aspectos, como descrito em (FORTES et al., 2016) e (SUNDARESWARAN; RAZIA BEGUM, 2004), sob os seguintes aspectos: 1) opera em um conjunto de soluções codificadas e não nas próprias soluções; 2) realiza um procedimento de busca a partir de um conjunto de soluções e não de uma única solução; 3) usa apenas valores da função de adequação não derivada ou outro conhecimento auxiliar e 4) usa regras de transição probabilísticas e não determinísticas. Por esses motivos, um AG multiobjetivo é proposto neste trabalho, para parametrizar um PSS por meio de simulações computacionais usando seus parâmetros para treinar um RNA.

#### 2.1.6 Métodos Computacionais com parâmetros dinâmicos

Os sistemas de potência são dinâmicos. Consequentemente, um projeto PSS deve ser capaz de estabilizar o sistema em diferentes pontos operacionais (P & Q) e utilizar técnicas a fim de alcançar um sistema estável para todos os pontos de operação. As análises de estabilidade em sistemas lineares são geralmente abordadas através da localização dos polos do sistema no plano S

ou dos valores próprios do modelo de sistema do espaço de estados. Todo o design dos modelos clássicos para controle de estabilidade do sistema de energia é linearizado em torno de um ponto operacional, o que acaba limitando o PSS (LI et al., 2018). As principais técnicas para contornar esses problemas são de controle adaptativo e RNA que são apresentados nos próximos subitens.

#### 2.1.6.1 Controle Adaptativo

Controle adaptativo é a denominação atribuída à ação de controles de sistemas capazes de modificar seus próprios parâmetros em resposta a alterações verificadas em algum módulo que esteja sendo monitorado. Neste sentido, adaptar-se significa mudar o comportamento em resposta a novas circunstâncias de operação com o objetivo de manter sempre um nível esperado de desempenho. O controle adaptativo é uma extensão natural dos sistemas realimentados clássicos (os quais já se ajustam a novas circunstâncias), buscando projetar controladores dotados de maior autonomia (ZUBEN, 2003).

A teoria de controle adaptativo foi muito ativa nos anos 50, pois a motivação era desenvolver sistemas de controle de voo para aeronaves supersônicas, já que os ganhos constantes não eram suficientes para sustentar a operação na região supersônica. Muitas das principais ideias de controle adaptativo foram concebidas nesta época, mas não havia hardware para implementações confiáveis, já que se empregava computadores analógicos dedicados (ZUBEN, 2003).

Para o amortecimento de oscilações tem-se mais recentemente algumas aplicações como as sugeridas em (MILLA; DUARTE-MERMOUD, 2016), (ZACHARIA et al., 2019) e (LALA; GALLARDO, 2020). Estas aplicações estão comparadas com as outras metodologias no Quadro 1.

#### 2.1.6.2 Redes Neurais

O aprendizado de máquina baseado em Inteligência Artificial (IA) é proposto para superar alguns destes problemas, aplicando algum tipo de técnicas de controle baseadas na medição das grandezas elétricas em tempo real. A diversidade de modelos RNA ganhou uma grande evolução ultimamente e é considerada um avanço no campo da IA. Cada modelo possui pontos fortes

e fracos, dependendo da aplicação e da situação em que será usado. Em problemas de engenharia, as RNA foram aplicadas para modelagem de sistemas, reconhecimento de padrões, aproximadores funcionais, reconhecimento de anomalias e classificação, com a capacidade de generalizar um modelo enquanto toma decisões sobre dados de entrada imprecisos (YOUSEFIAN; KAMALASADAN, 2017).

Algumas abordagens de RNA baseadas no aprendizado de máquina para a estabilidade dos ângulos do rotor são usadas para modelar/identificar e controlar a própria planta como em (GHANDI; JOSHI, 2019; KAMALASADAN et al., 2014; CHATURVEDI; MALIK, 2005). A dificuldade em implementar esse tipo de prática representa uma extrema confiança necessária na metodologia para amortecer adequadamente as oscilações, já que a RNA deve funcionar perfeitamente nas duas situações. Como alternativa, a RNA pode ser usado para definir os ganhos convencionais do PSS4b, tornando-o ligeiramente próximo do formato utilizado mundialmente nas unidades geradoras. Um PSS neural treinado usando controladores lineares locais em um esquema de ganho de escala é mostrado em (BARREIROS et al., 2005; RANA et al., 2019; BHUTTO et al., 2020; CHATURVEDI; MALIK, 2005; MASROB et al., 2017; KUMAR et al., 2016). As melhorias adotadas pela metodologia aqui proposta em contraste com estas últimas referências são que o AG é proposto para ajustar os ganhos. Essa técnica resulta em um melhor desempenho de acordo com os resultados apresentados nesta tese.

A maioria dos trabalhos precisa de muitos pontos de operação para treinar a rede neural como em (SHOJAEI et al., 2015; MAGANGANE; FOLLY, 2013; BHUTTO et al., 2020; KUMAR, et al., 2016; BARREIROS et al., 2005; GHANDI; JOSHI, 2019; KAHOUALI et al., 2019; RANA et al., 2019). Este trabalho apresenta uma nova metodologia para o treinamento da rede neural que requer muito menos pontos de carga para representar eficientemente o sistema de energia. Difere do método de treinamento em (KAHOULI et al., 2019; RANA et al., 2019), exigindo apenas a otimização dos ganhos do PSS4b e não da saída dele, o que facilita a reprodução em outros sistemas. A metodologia adotada para treinar o RNA pode ser usada em outros sistemas de controle e seis funções diferentes de treinamento também foram comparadas.



A rede neural NARX é proposta nesta tese como o RNA. Não requer atrasos externos, como em (BARREIROS et al., 2005; GHANDI; JOSHI, 2019; CHATURVEDI; MALIK, 2005; KAMALASADAN et al., 2014). A NARX é uma classe de RNA que demonstrou ser adequada para modelar sistemas não lineares e especialmente séries temporais. A aplicação principal da NARX é nos sistemas de controle.

Algumas qualidades das redes NARX é o algoritmo gradiente de aprendizado descendente são:

- o aprendizado é mais eficaz em redes NARX do que em outras redes, pois o gradiente descendente é melhor no NARX (DIACONESCU, 2008).
- essas redes convergem muito mais rapidamente e generalizam melhor do que outras redes (DIACONESCU, 2008).

## 2.2 COMPARATIVO ENTRE MÉTODOS PARA PARAMETRIZAÇÃO DO PSS

Um comparativo entre métodos para parametrização do PSS com a finalidade de apontar, de uma forma mais clara, as lacunas preenchidas pela metodologia AG-NARX-PSS proposta nesta tese encontra-se no Quadro 1.

Métodos mais recentes para amortecimento de oscilações via excitação dos geradores síncronos são comparados entre a utilização ou não de técnicas de otimização, otimização multiobjetivo, ponto de operação dinâmico, rede neural alternando ganhos do PSS, tipo do PSS utilizado, modelo de rede neural, se a rede neural precisa identificar o modelo da planta, sistema multimáquinas e método de treinamento da rede neural.

## 2.3 PSS NO CONTEXTO DAS REDES ELÉTRICAS INTELIGENTES

As redes elétricas tradicionais estão se modernizando para as chamadas Redes Elétricas Inteligentes (REI), as quais incluem o desenvolvimento de avançadas tecnologias de transmissão, bem como a utilização de otimização em várias etapas dela. A melhoria do sistema de controle de excitação é também muito importante porque se espera que nas REIs os estabilizadores e os *flexible*

*alternating current transmission system* (FACTS) (LEON, 2012) sejam incluídos de forma coordenada.

Os benefícios de tratar as linhas de transmissão como ativos controláveis e incorporar a mudança de transmissão nas operações do sistema de energia são múltiplos. Foi mostrado por (HUANG; WANG, 2014) que ao se despachar linhas de transmissão juntamente com a geração, pode-se alcançar uma economia de 25% no custo de despacho. Com o aumento da penetração das energias renováveis no sistema de transmissão, a inércia efetiva do sistema é reduzida e a estabilidade do ângulo do rotor do sistema após grandes distúrbios pode ser significativamente afetada (GAUTAM et al., 2009).

Quadro 1 - Métodos recentes para parametrização do PSS

Autor	Otimização	Otimização MO	Ponto de Operação Dinâmico	Neural Scheduling	PSS de Normas	Modelo da Neural	Precisa de identificação da planta	Sistema Multimáquinas	Método de Treinamento
(LALA; GALLARDO, 2020)	Sim	-	Sim	Não	Não	-	-	Sim	-
(ZACHARIA et al., 2019)	Não	-	Sim	Não	Não	-	-	Sim	-
(MILLA; DUARTE-MERMOUD, 2016)	Sim	-	Sim	Não	Não	-	-	Não	-
(SANTRA; SUBRATA, 2016)	Sim	-	Sim	Não	Não	-	-	Sim	-
(ISBEIH et al., 2019)	Sim	-	Sim	Não	Não	-	-	Sim	-
(KISHOR et al., 2014)	Sim	-	Sim	Não	Não	-	-	Não	-
(FORTES et al., 2016)	AG	Sim	Não	-	Não	-	-	-	-
(SHAYEGHI et al., 2018)	Honeybee Mating	Sim	Não	-	Não	-	-	-	-
(WANG et al., 2018)	Particle Swarm	Sim	Não	-	Não	-	-	-	-
(SAHU et al., 2019)	WOA	Não	Não	-	Não	-	-	-	-
(BUTTI et al., 2020)	WOA	Não	Não	-	Não	-	-	-	-
(LI et al., 2018).	H <sub>2</sub>	Sim	Sim	Não	Não	Feedforward	Não	Sim	Treinado on-line
(SHOJAEI et al., 2015)	Não	-	Sim	Não	Não	Feedforward	Não	Não	Vários pontos de operação
(MAGANGANE et al., 2013)	Não	-	Sim	Não	Não	Feedforward	Não	Não	Vários pontos de operação
(BHUTTO et al., 2020)	Não	-	Sim	Sim	Não	Feedforward	Não	Não	Vários pontos de operação
(CHATURVEDI et al., 2005)	Não	-	Sim	Sim	Não	Generalized neuron	Sim	Não	Treinamento on-line e off-line
(MASROB et al., 2017)	Não	-	Sim	Sim	Sim	Feedforward	Não	Não	Não mencionado no artigo
(KUMAR et al., 2016)	Não	-	Sim	Sim	Não	Feedforward	Não	Não	Vários pontos de operação
(ANSARI et al., 2018)	Não	-	Sim	Não	Não	Feedforward	Não	Não	Não mencionado no artigo
(BARREIROS et al., 2005)	Não	-	Sim	Sim	Não	Feedforward + Delay	Não	Não	Vários pontos de operação
(GHANDI; JOSHI, 2019)	Sim, para os pesos da RNA	-	Sim	Não	Não	Feedforward + Delay	Sim	Não	Vários pontos de operação
(JHANG et al., 2018)	Não	-	Sim	Não	Não	Feedforward + Delay	Não	Sim	Não mencionado no artigo
(KAHOULI et al., 2019)	NSGA-II	Sim	Sim	Não	Não	Feedforward	Não	Sim	Vários pontos de operação calculados por NSGA-II
(KAMALASADAN, 2014)	Não	-	Sim	Não	Não	Feedforward + Delay	Sim	Sim	Treinamento on-line e off-line
(RANA et al., 2019)	BSA	Sim	Sim	Sim	Não	Feedforward	Não	Não	Vários pontos de operação calculados por BSA
Proposta	AG	Sim	Sim	Sim	Sim	NARX	Não	Sim	Nova técnica para geração de dados para treinamento da rede neural

Fonte: Elaborada pelo autor.

O tipo de controle de potência empregado para a geração renovável afeta diretamente o ângulo do rotor e a velocidade dos geradores síncronos (TANG et

al., 2015). (VITTAL, et al., 2012) mostra que quando o fluxo de potência muda, a forma como a turbina eólica fornece suporte de energia reativa ao sistema é crítica para manter a estabilidade do ângulo do rotor das unidades convencionais e minimizar o desvio da tensão de campo.

Isto também se aplica ao controle da potência ativa uma vez que as oscilações são produzidas por diferenças de potência ativa entre geração e consumo. Portanto, a implementação de estratégias de controle adequadas nas fontes renováveis, particularmente o controle de tensão terminal, pode diminuir os requisitos de energia das unidades síncronas convencionais e ajudar a mitigar grandes oscilações do ângulo do rotor. Existem várias técnicas para este propósito, como métodos de controle ideais, métodos robustos, métodos de função de energia e projetos baseados em IA para o controle de estabilidade do ângulo do rotor do sistema de energia integrado renovável (YOUSEFIAN; KAMALASADAN, 2017).

## 2.4 CONSIDERAÇÕES FINAIS

Este capítulo apresentou os principais métodos de parametrização do PSS. Todo o design dos modelos clássicos para controle de estabilidade do sistema de energia é linearizado em torno de um ponto operacional, o que acaba limitando o PSS. Os métodos computacionais conseguem levar os estabilizadores próximos ao seu desempenho máximo, porém, acabam não atuando de forma a considerar mais pontos de operação do sistema. As principais técnicas para contornar esses problemas são os métodos de parametrização dinâmica, os quais utilizam RNA e controle adaptativo. Na próxima seção é apresentada a modelagem do sistema.

### 3 MODELAGEM DO SISTEMA

Neste Capítulo são apresentadas a formulação do problema de estabilidade, sistema de excitação do gerador síncrono, modelo da turbina e regulador de velocidade e o estabilizador a ser utilizado IEEE PSS4B.

#### 3.1 FORMULAÇÃO DO PROBLEMA DE ESTABILIDADE

A estabilidade de um sistema de potência é a sua capacidade de recuperação das condições de equilíbrio operacional após a exposição a um distúrbio. A dinâmica de cada barramento do gerador síncrono é descrita pela tensão terminal  $V_t|\delta$ , em que  $\delta$  é o ângulo do rotor em relação a referência da rotação síncrona. A instabilidade ocorre quando as oscilações angulares são aumentadas em alguns geradores, o que leva à sua perda total de sincronismo com outras máquinas (SHAYEGHI et al., 2013). Uma tarefa importante para analisar um sistema de energia é ter um modelo adequado. A oscilação de frequência no modo comum pode ser descrita aproximadamente, assumindo que haja geradores e cargas respondendo às variações de velocidade do sistema, negligenciando as perdas de transmissão. Em seguida, pode ser descrito (1) como:

$$2H\Delta\omega(t) = \sum_{i=1}^m \Delta P_{G,i}(t) - \sum_{j=1}^n P_{L,j}(t) \quad (1)$$

em que  $H$  é o tempo de inércia equivalente,  $\Delta\omega$  é o desvio da média de velocidade dos geradores síncronos,  $t$  é o tempo,  $P_G$  é a geração total de potência ativa e  $P_L$  é o total do consumo de potência ativa incluindo as perdas.

Para estudar e simular a estabilidade dos sistemas de energia elétrica, o primeiro passo é modelar cada parte dele. Um modelo de espaço de estado de sexta ordem pode ser usado para representar as partes elétricas da máquina síncrona. Esse modelo considera a dinâmica dos enrolamentos do estator, campo da máquina e amortecedor (MOEINI, 2018). O sistema mecânico é descrito pelas equações (2) e (3).


$$\Delta\omega(t) = \frac{1}{2H} \int_0^t (T_m - T_e) dt - K_d \Delta\omega(t) \quad (2)$$

$$\omega(t) = \Delta\omega(t) + \omega_0 \quad (3)$$

onde,  $T_m$  é o torque mecânico,  $T_e$  é o torque eletromagnético,  $K_d$  é o coeficiente de amortecimento e  $\omega_0$  é a velocidade de operação.

A potência mecânica é igual ao produto do torque T e a velocidade da máquina,  $\omega$ , ou seja,  $P_m = T \cdot \omega$ . No entanto, com  $\omega \cong 1$  pu, mesmo em condições transitórias, é possível usar a aproximação  $T \cong P_m$ , resultando em um modelo de máquina em que o efeito de amortecimento intrínseco na dinâmica de torque foi adicionado através do coeficiente de amortecimento  $K_d$ , multiplicando o desvio de velocidade (CHOW; SANCHEZ-GASCA, 2020) e (XIE et al., 2019). A Figura 1 mostra um diagrama de blocos da função de transferência do sistema mecânico para a máquina síncrona.

Figura 1 – Diagrama de blocos da função de transferência do sistema mecânico do gerador síncrono

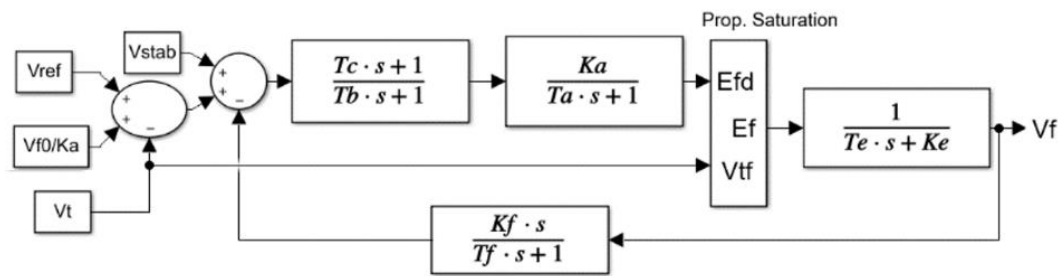


Fonte: adaptada de (IEEE, 2007)

### 3.2 A EXCITAÇÃO DO GERADOR SÍNCRONO

O sistema de excitação é descrito em (IEEE, 2007) sem a função de saturação da excitatriz estática. Seus elementos básicos são o regulador de tensão e a excitatriz cujas funções de transferência estão apresentadas na Figura 2:

Figura 2 – Modelo do sistema de excitação



Fonte: adaptada de (IEEE, 2007)


Na Figura 2, o ganho  $K_a$  e a constante de tempo  $T_a(s)$  representam um sistema de primeira ordem que representa o regulador principal. A constante  $K_e$  e a constante de tempo  $T_e(s)$  são usadas para modelar a operação do excitador. Constantes  $T_b(s)$  e  $T_c(s)$  são as constantes do compensador de avanço e atraso. O ganho  $K_f$  e a constante de tempo  $T_f(s)$  representa o sistema de medição da tensão de campo como um *feedback* derivativo. Os valores iniciais da tensão de campo  $V_{f0}$  (pu),  $V_{ref}$  são as referências de tensão de campo,  $V_t$  é a tensão do terminal do gerador e  $V_{stab}$  é o sinal do PSS.

O PSS escolhido foi o modelo IEEE® St. 421.5 PSS4B (IEEE, 2005), com transdutores de velocidade integrados cujos parâmetros são fixados de acordo com as especificações do fabricante. Ele possui algumas vantagens em relação aos outros estabilizadores, principalmente quando utilizado em problemas de otimização. Isto será descrito com mais detalhes na seção 3.4.

### 3.3 MODELO DA TURBINA E REGULADOR DE VELOCIDADE

O sistema de controle de velocidade consiste em um regulador proporcional, um relé de velocidade e um servo motor que controla a abertura do distribuidor. É semelhante ao modelo proposto em (IEEE, 2003). A Figura 3 mostra o diagrama de blocos da função de transferência do modelo do regulador de velocidade da turbina onde  $P_{ref}$  é a referência de energia elétrica,  $\omega_{ref}$  é a referência de velocidade,  $K_p$  é um ganho proporcional,  $R_p$  é o estatismo permanente (pu) e  $T_{sm}$  (s) representa o relé de velocidade.


Figura 3 – Diagrama de blocos da função de transferência do regulador de velocidade da turbina



Fonte: adaptada de (IEEE, 2007)

A Figura 4 representa o modelo do servo motor e seu controlador.

Figura 4 – Diagrama de blocos da função de transferência do servo motor e seu controlador



Fonte: adaptada de (IEEE, 2007)


Turbinas a vapor são usadas tanto em usinas nucleares quanto em usinas movidas a combustíveis fósseis. O vapor passa primeiro em turbinas de alta pressão, depois em turbinas de pressão intermediária e, finalmente, por uma e até três turbinas de baixa pressão. A Figura 5 apresenta uma turbina a vapor e a Figura 6 apresenta suas características:

Figura 5 – Exemplo de Turbina a Vapor do tipo composta



Fonte: (SANDVIK et al., 2013)

Figura 6 – Partes da turbina a vapor



Fonte: (SANDVIK et al., 2013)

Na Figura 6, a numeração se refere à:

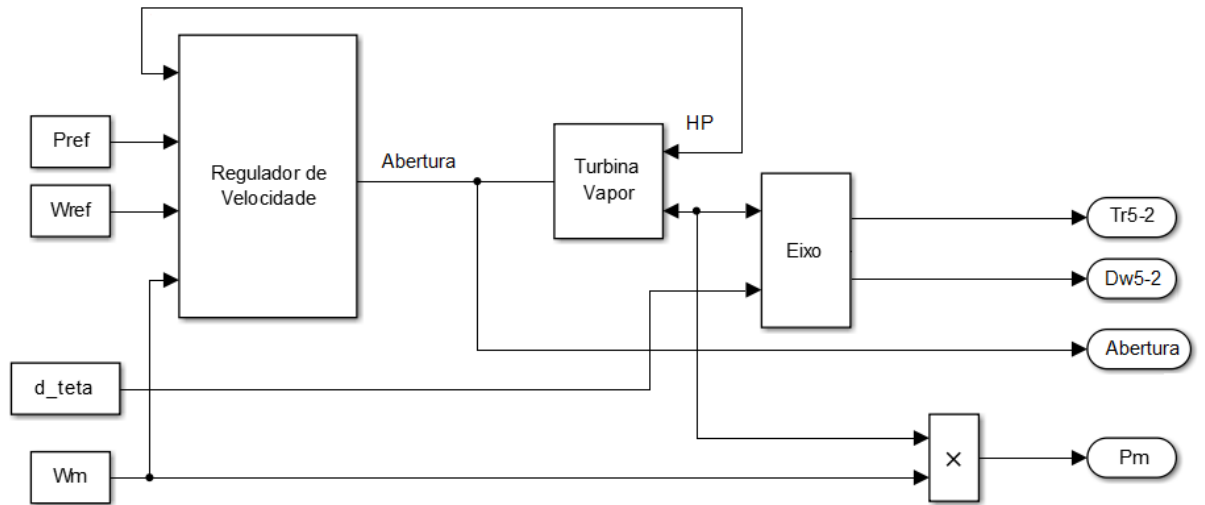
- 1) Pá de turbina;
- 2) Carcaça de turbina;
- 3) Carcaça de turbina;
- 4) Eixo de turbina a vapor;
- 5) Diafragma de turbina a vapor.

O modelo da turbina a vapor e do regulador de velocidade aqui utilizados foram propostos por IEEE (1985) que implanta uma turbina com quatro estágios e um eixo de até quatro massas. A Figura 7 apresenta o modelo lógico completo da turbina e o regulador de velocidade apresentado em (IEEE, 1985).

O regulador de velocidade da turbina possui um ganho proporcional, um relé de velocidade e um servo-motor controlando a abertura do distribuidor, (IEEE, 1985). O modelo completo do regulador é representado na Figura 8.



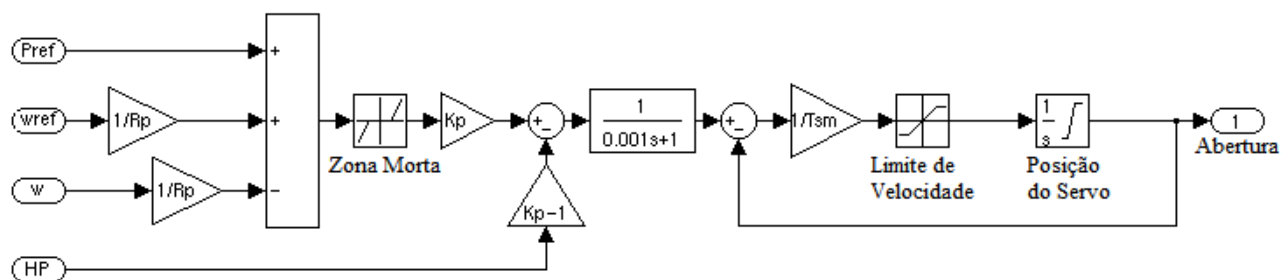
Figura 7 - Modelo da Turbina com o Regulador de Velocidade



Fonte: adaptada de (IEEE, 1985)

- $W_{ref}$ : O valor desejado de velocidade em pu;
- $P_{ref}$ : Referência de potência elétrica em pu;
- $d_{theta}$ : Ângulo de carga;
- $d_{w5-2}$ : Desvios de velocidade em pu das respectivas massas;
- $T_r$ : Torque transmitido pelas respectivas massas;
- **Abertura**: Abertura do distribuidor em pu;
- $P_m$ : Potência mecânica em pu;
- $T_{r5-2}$ : Constantes de tempo da turbina em segundos.
- **Hp**: Potência injetada na turbina;

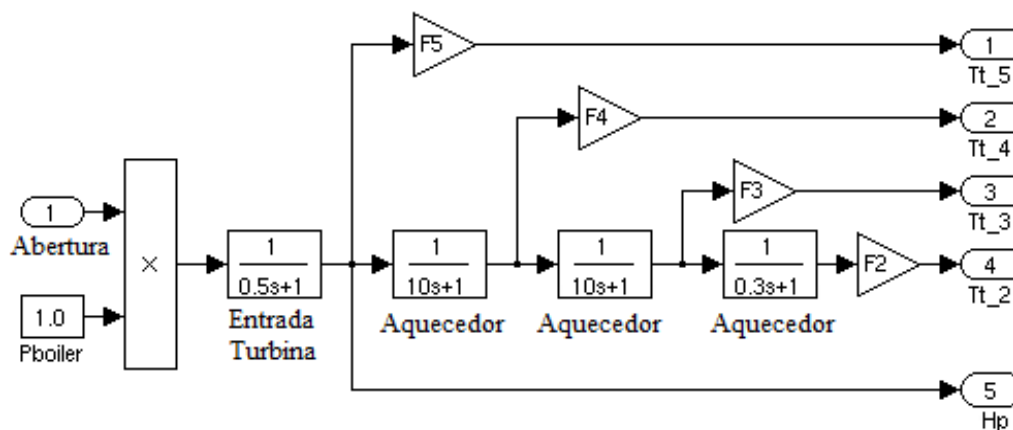
Figura 8 - Modelo do Regulador de Velocidade



Fonte: adaptada de (IEEE, 1985)

A turbina a vapor tem quatro estágios que foram modelados por uma função de transferência de primeira ordem, conforme Figura 9. O primeiro estágio representa a tomada de vapor enquanto os demais estágios representam os aquecedores. A pressão do boiler é considerada constante e igual a 1 pu. As variáveis  $F_2$  a  $F_5$  representam os vários estágios do eixo.

Figura 9 - Modelo do Regulador de Velocidade



Fonte: adaptada de (IEEE, 1985)

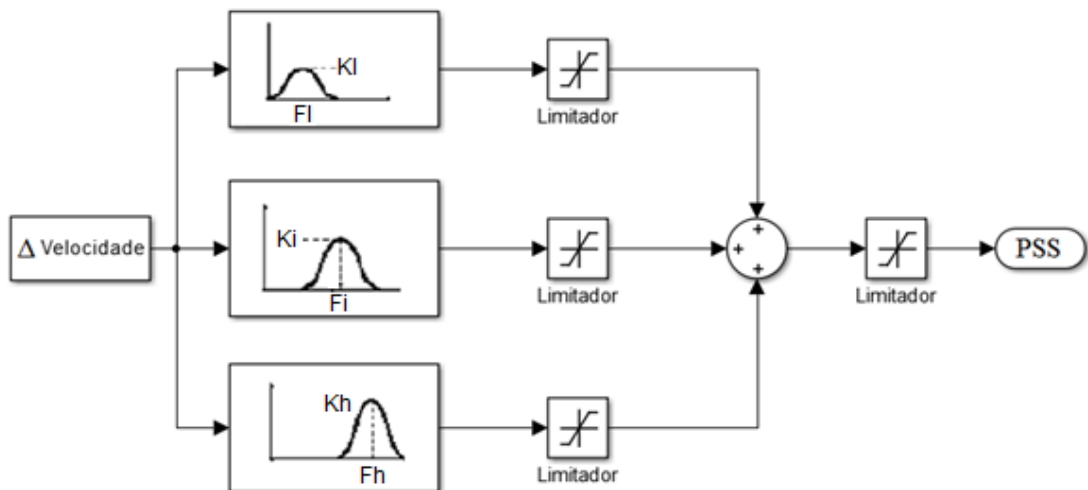
### 3.4 IEEE PSS4B

A necessidade de amortecimento numa ampla faixa de frequências motivou o conceito de um estabilizador multi-banda conhecido como *multiband power system stabilizer* (MB-PSS). Seu nome revela que sua estrutura trabalha em múltiplas bandas dedicadas às baixas, médias e altas frequências de oscilação. A baixa frequência é associada com o sistema elétrico de um modo geral. A frequência intermediária corresponde ao modo interárea e a de alta frequência, às oscilações em modo local.

Atualmente no Brasil, ONS (2008) exige que geradores maiores que 30MW sejam equipados com sistemas de excitação e estabilizadores do tipo IEEE PSS2B. Porém, o IEEE PSS4B é uma evolução do antecessor e pode ser aplicado de uma forma mais simples em um problema de otimização, dividindo-se em três bandas de atuação. A Figura 10 abaixo é a representação conceitual do PSS4B. As três bandas são compostas por filtros passa banda, um ganho e um limitador. A saída do estabilizador é a soma das bandas com mais de um limite final. A frequência central é representada por  $F_L$ ,  $F_I$ , e  $F_H$ . A magnitude do

pico da frequência pode ser ajustada independentemente através dos três ganhos  $K_L$ ,  $K_I$ , e  $K_H$ . Todos os parâmetros devem ser ajustados conforme a interação da máquina com o sistema. Portanto, apenas seis parâmetros são necessários para um ajuste simplificado, conforme apresentado em (IEEE, 2005).

Figura 10 - Representação conceitual do PSS4B



Fonte: adaptada de IEEE® St. 421.5

A

Figura 11 apresenta o modelo completo do PSS4B apresentado pela IEEE na norma St. 421.5. Vários ganhos e constantes de tempo são necessários para representar o modelo conceitual da Figura 10.

O método mais utilizado para a parametrização do PSS4B conta com parâmetros simplificados. Para transformar o IEEE PSS4B apresentado na

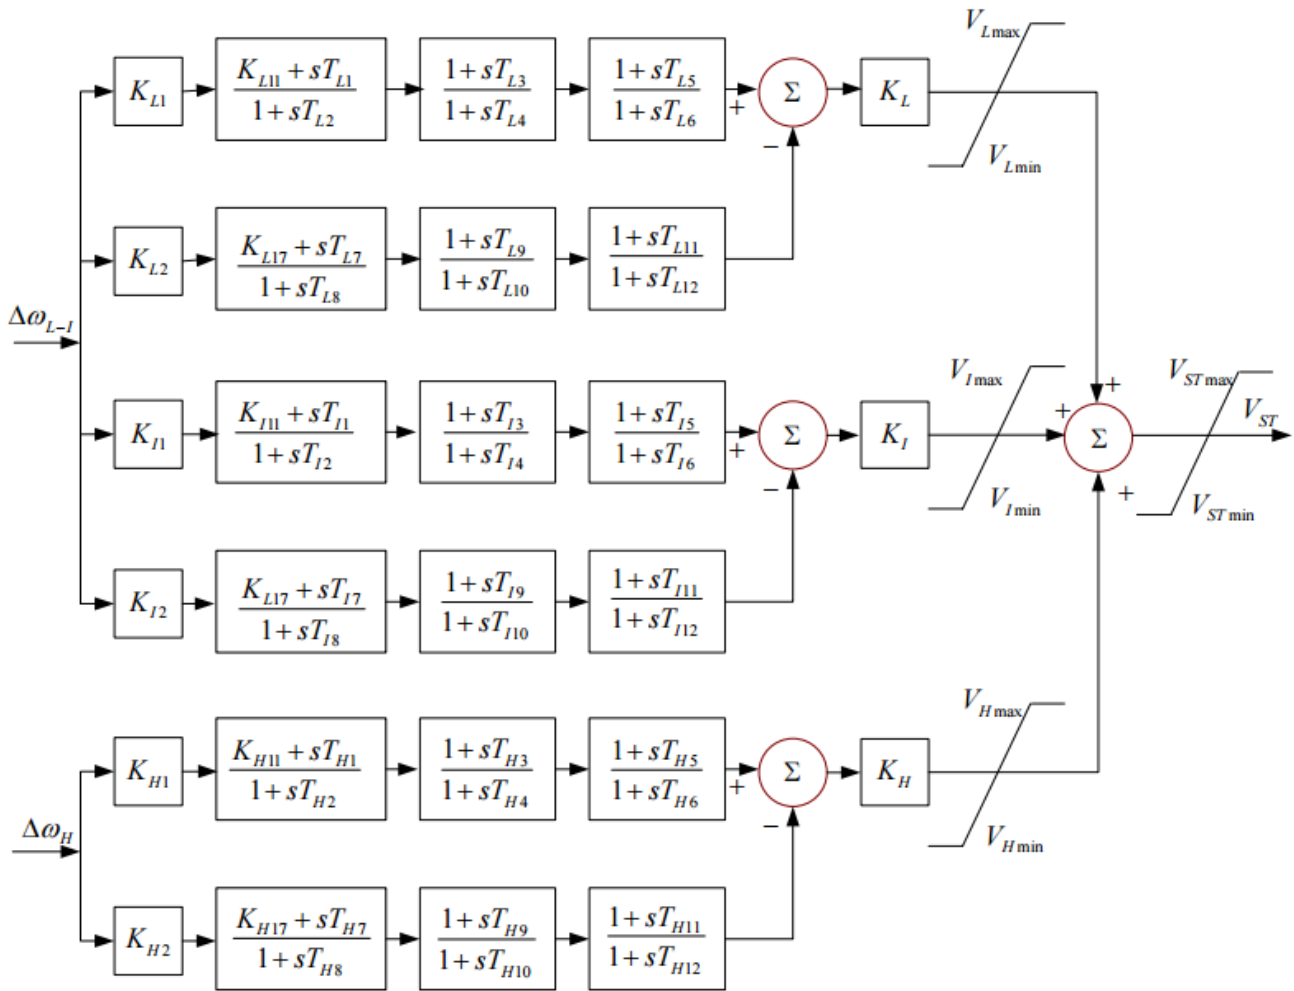
Figura 11 no modelo conceitual é possível fazer com apenas alguns blocos de avanço e atraso.

A norma IEEE® St. 421.5 apresenta uma forma de converter um ganho e uma frequência central em um filtro passa-banda via filtro avanço e atraso. Isto facilita a utilização do AG para otimizar os ganhos, pois assim apenas seis variáveis são requisitadas pelo PSS.

A Figura 12 apresenta o diagrama de blocos desta conversão. Basicamente dois blocos de avanço e atraso de fase são utilizados e mais alguns ganhos que são sugeridos pela norma. Apenas um ramo foi representado na

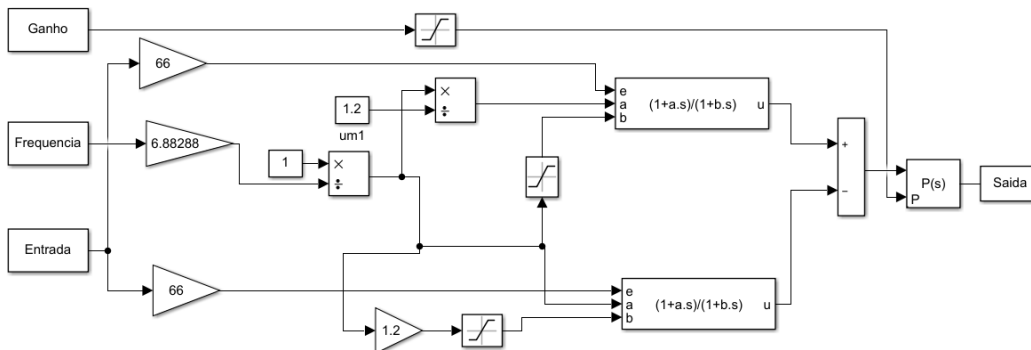
Figura 12, correspondo a apenas um ganho e uma frequência do PSS4b, para representação completa seriam necessário três ramos.

Figura 11 - Estabilizador de Potência PSS4B completo



Fonte: adaptada de IEEE© St. 421.5

Figura 12 – Representação do PSS4b com filtros avanço e atraso



Fonte: elaborada pelo autor

### 3.5 CONSIDERAÇÕES FINAIS

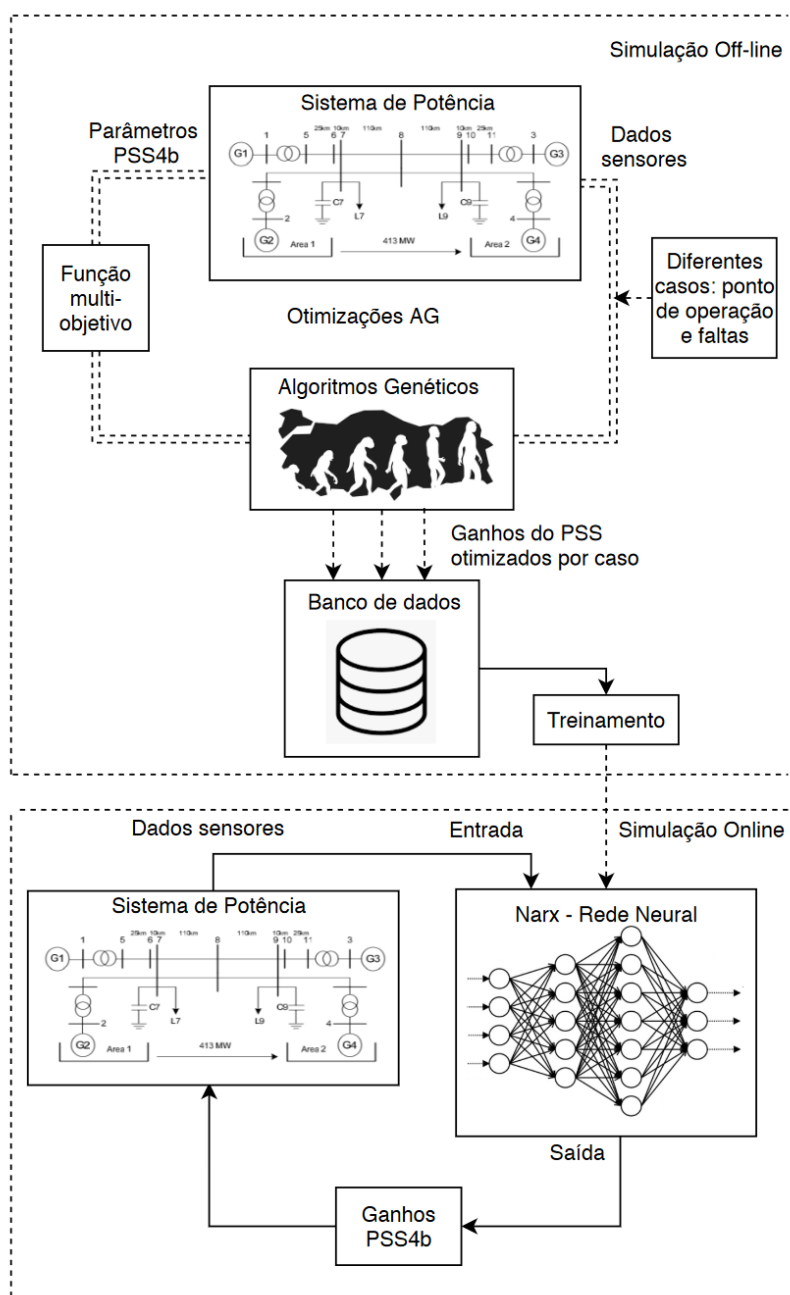
Este capítulo apresenta a formulação do problema de estabilidade, modelagem do gerador síncrono e turbina. Por fim, é exibido o estabilizador utilizado IEEE PSS4b, o qual é o estabilizador mais indicado para utilizar em conjunto com otimização por utilizar apenas seis parâmetros para otimização e conseguir compensar três diferentes frequências de oscilação. No próximo capítulo, é apresentada a metodologia proposta nesta tese.

## 4 METODOLOGIA PROPOSTA

### 4.1 INTRODUÇÃO

O objetivo desta tese é apresentar uma nova metodologia para amortecer as oscilações de potência. A Figura 13 ilustra a metodologia proposta, a qual é dividida em duas partes, as simulações off-line e on-line.

Figura 13 – Metodologia Proposta



#### 4.1.1 Metodologia para a simulação off-line

Primeiramente, na parte da metodologia chamada de simulação off-line, uma otimização do PSS via AG é proposta. Uma análise de sensibilidade do AG é descrita com o objetivo de tirar o máximo da abordagem. Os parâmetros que mais fizeram diferença para minimizar o amortecimento das oscilações foram a mutação, população inicial, funções objetivo e população total. Cada otimização foi aplicada três vezes, porém, não existiu grandes problemas em relação a isto, como demonstrado no capítulo 5.

No sistema base, ainda no modo off-line, diferentes casos de carga e curtos-circuitos foram otimizados via AG com o intuito de representar o sistema da melhor forma possível para o desenvolvimento treinamento da rede neural.

#### 4.1.2 Metodologia simulação on-line

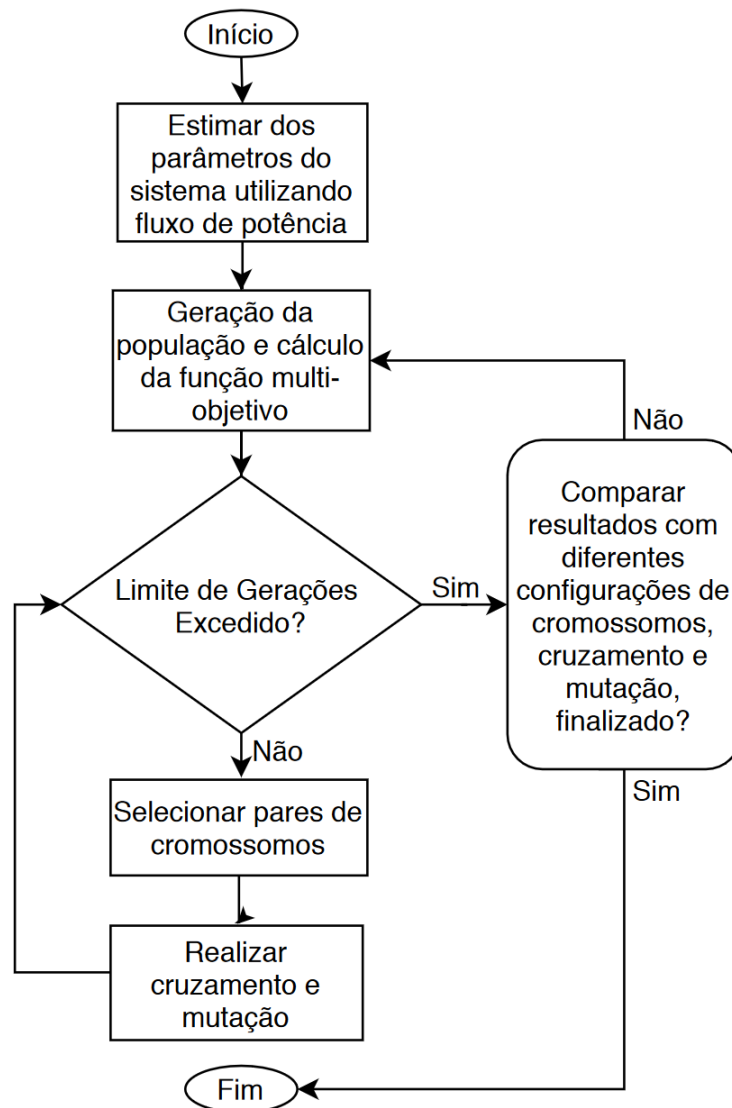
A parte da simulação on-line da metodologia consiste fundamentalmente no treinamento da rede neural NARX. Um novo método para geração de dados para treinamento da rede neural é proposto por nesta tese. Este consiste na utilização do banco de dados determinado previamente pelo AG para diferentes configurações de carga e sua principal diferença em relação à bibliografia é a modificação dos valores dos ganhos do PSS a fim de gerar dados, os quais facilitam a representação do sistema para a rede NARX. Desta forma, ela é capaz de alterar os parâmetros do estabilizador em tempo real, garantindo o amortecimento das oscilações para todos os casos, como pode ser observado no capítulo dos resultados.

### 4.2 ALGORITMO GENÉTICO (AG)

#### 4.2.1 Otimização com o AG proposto

O Apêndice A apresenta uma introdução sobre os AG. A Figura 14 apresenta o fluxograma da otimização do AG descrito neste trabalho. No caso do PSS a otimização tem o objetivo de minimizar o *overshoot* e o tempo de estabilização das oscilações. O Apêndice D apresenta a função do custo global para o AG.

Figura 14 – Diagrama da otimização via AG



Fonte: Elaborada pelo autor

O primeiro passo é estimar os parâmetros iniciais do sistema com o fluxo de potência. Depois disso, o AG gera uma população e avalia a função objetivo em que a resposta da planta é verificada. Em seguida, os índices, representando o desempenho de cada variável controlada são comparados com as últimas simulações sob diferentes parâmetros do AG.



#### 4.2.2 Função multiobjetivo proposta

A função multiobjetivo usada nesta tese é baseada no índice de performance: *the Integral Squared Error* (ISE), *Integral Absolute Error* (IAE), *Integral Time Multiply Squared Error* (ITSE) e *Integral Time Squared Error* (ITSE). As equações 4 a 7 definem matematicamente os índices:

$$ISE = \int_0^{\infty} e(t)^2 dt \quad (4)$$

$$IAE = \int_0^{\infty} |e(t)| dt \quad (5)$$


$$ITAE = \int_0^{\infty} t|e(t)| dt \quad (6)$$

$$ITSE = \int_0^{\infty} te(t)^2 dt \quad (7)$$

onde,  $e$  é o erro e  $t$  é o tempo da simulação.

A Figura 15 ilustra a função objetivo da ITSE. A entrada do AG é o resultado da função objetivo. O sinal de erro resulta da subtração da referência do sinal de P do sinal de potência elétrica medido. Sua saída é usada para calcular o melhor resultado entre os parâmetros definidos pelas populações de AG.

Figura 15 – Exemplo de função objetivo ITSE em bloco lógico



Fonte: Elaborada pelo autor

A otimização multiobjetivo (MOO) envolve a otimização de dois ou mais objetivos ao mesmo tempo. O problema se torna desafiador quando os objetivos entram em conflito entre si, ou seja, quando a solução ideal de uma função objetivo é diferente da outra. Na solução de tais problemas, com ou sem a presença de restrições, isso origina um conjunto conhecido como soluções ótimas de Pareto. Por outro lado, o método de escalarização cria funções multiobjetivo que são transformadas em uma única solução utilizando pesos. Existem três tipos de pesos no método de escalarização no qual os pesos são iguais, pesos ranqueados pelo centro geométrico e pesos classificados por soma (CHEN; ZHANG, 2018; DEB, 2001).

O método de escalarização permite que a função multiobjetivo crie uma única solução cujo peso seja determinado antes do processo de otimização. O método de escalarização incorpora funções multiobjetivo na função de aptidão escalar, conforme representado na seguinte equação (CHEN; ZHANG, 2018):

$$F(x) = w_1 f_1(x) + w_2 f_2(x) + \dots + w_n f_n(x). \quad (8)$$

O peso de uma função objetivo determina a solução da função e a prioridade de desempenho. Uma função objetivo com um peso maior tem uma prioridade mais alta se comparada àquelas com pesos menores. Além disso, existem três abordagens para determinar o peso da escalarização que utiliza: pesos iguais, pesos *Rank Order Centroid* (ROC) e pesos *Rank-Sum* (RS).

Nesta tese, o método de escalarização foi utilizado e as funções têm o mesmo peso. A função multi-objetivo aqui proposta é representada pela equação (9):

$$F_{m.o.} = \frac{(ISE + IAE + ITAE + ITSE)}{4} \quad (9)$$

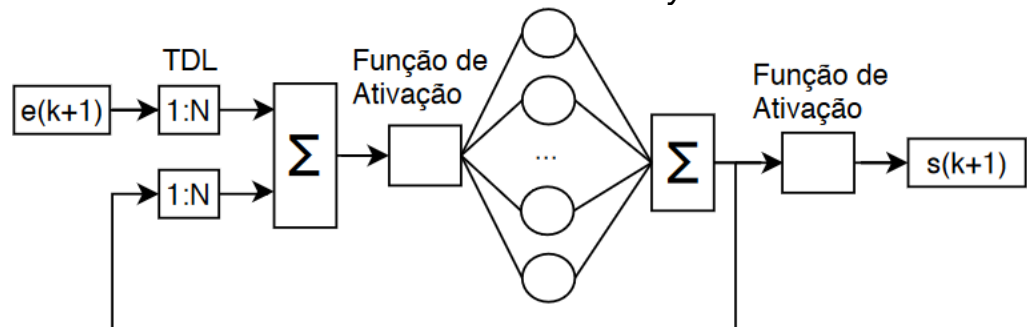
Esta função é proposta após comparar seu desempenho com um único índice de desempenho. O objetivo da otimização é minimizar o erro com o AG. No capítulo 5 são apresentados os resultados, em que foram verificadas diferentes restrições e parâmetros de AG.

### 4.3 MODELO DE REDE NEURAL NARX

O Apêndice B apresenta uma introdução sobre as RNA. O grande diferencial das redes recorrentes em relação às perceptrons é o fato destas possuírem pelo menos um laço de realimentação. Esse tipo de estrutura tem um impacto profundo na capacidade de aprendizagem e no desempenho da rede neural. A realimentação utiliza elementos de atraso unitário, representada por  $z^{-1}$  para representar um comportamento dinâmico não linear (HAYKIN, 2009).

A rede neural NARX (Non-linear Autoregressive with Exogenous Inputs) é uma variante da rede recorrente que é muito utilizada em sistemas dinâmicos não lineares. Ela é considerada como mais eficaz do que as redes recorrentes convencionais, pois possuem maior eficácia na aprendizagem devido ao gradiente descendente (algoritmo de otimização que realiza o ajuste de parâmetros de forma iterativa), sua memória integrada que proporciona um menor caminho para a propagação do gradiente de informação quando a rede é em malha aberta (VILELA, 2016). Figura 16 apresenta a estrutura de uma rede neural com *delays*.

Figura 16 – Estrutura de uma rede neural com *delays*



Fonte: Autor.

Para encontrar a arquitetura apropriada da rede NARX, basta determinar os melhores *tapped delay line* (TDL) para a entrada exógena, número de camadas ocultas e número de neurônios para cada camada oculta. O processo de treinamento é feito completamente off-line por diversas funções (TRONCI; BARATTI, 2017). Uma análise de sensibilidade com diferentes números de

camadas ocultas, atrasos, neurônios e diferentes funções de treinamento é apresentada nesta tese.

A equação (10) representa o modelo NARX. Ela é um sistema não-linear discreto comumente utilizado que pode ser matematicamente representado como:

$$s(k) = f\{e(k-1), e(k-2), \dots, e(k-l), s(k-1), s(k-2), \dots, s(k-m)\}, \quad (10)$$


onde  $e(k) \in \mathbb{R}$  e  $s(k) \in \mathbb{R}$  representam as entradas e saídas da NARX no tempo discreto,  $k$ .  $l \geq 0$  e  $m \geq 0$  são as memórias de entradas e saída (DIACONESCU, 2008).

A função desconhecida  $f(\cdot)$ , geralmente não-linear, ou seja, pode ser aproximada, por exemplo, por uma rede de alimentação direta de múltiplas camadas.

#### 4.3.1 Proposta de arquitetura para rede NARX

A saída da rede NARX pode ser considerada como uma estimativa da saída de algum sistema dinâmico não linear que está sendo modelado (NARENDRA; PARTHASARATHY, 1991). A saída é realimentada para a entrada da rede neural de feedforward como parte da arquitetura NARX padrão, conforme mostrado na figura da esquerda da Figura 17. Como a saída verdadeira está disponível durante o treinamento da rede, uma arquitetura paralela em série pode ser criada, na qual a saída verdadeira é usada em vez de retornar a saída estimada, como mostra a Figura 17 abaixo. Isso tem duas vantagens. A primeira é que a entrada para a rede feedforward é mais precisa. A segunda é que a rede resultante possui uma arquitetura puramente avançada e a retropropagação estática pode ser usada para treinamento (NARENDRA; PARTHASARATHY, 1991).


Figura 17 – Arquiteturas paralela e série paralela da rede NARX



Fonte: Autor.

As duas topologias foram verificadas. Com inspiração na arquitetura utilizada em (TRONCI; BARATTI, 2017), a Figura 18 mostra as entradas e saídas da topologia do NARX que teve a melhor resposta.

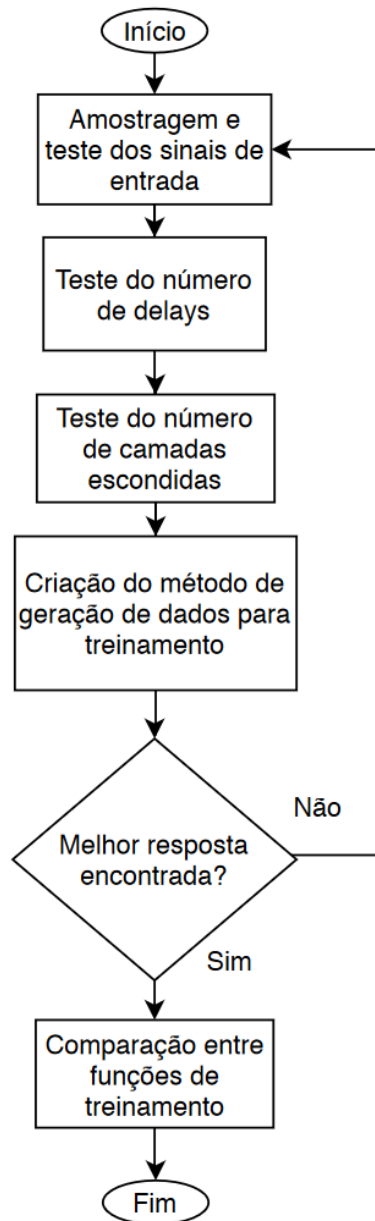
Figura 18 – Topologia da rede NARX proposta



Fonte: Elaborada pelo autor

A variável  $V_{stab}$  é a saída do PSS4b e  $\Delta\omega$  é o desvio de velocidade. Ambos os sinais foram escolhidos depois de obterem uma melhor resposta quando comparado com sinais de entrada sendo a P e Q e outra topologia utilizando P, Q,  $V_{stab}$  e  $\Delta\omega$ . A Figura 19 apresenta a lógica seguida para design da rede neural.

Figura 19 – Diagrama lógico de design da rede neural



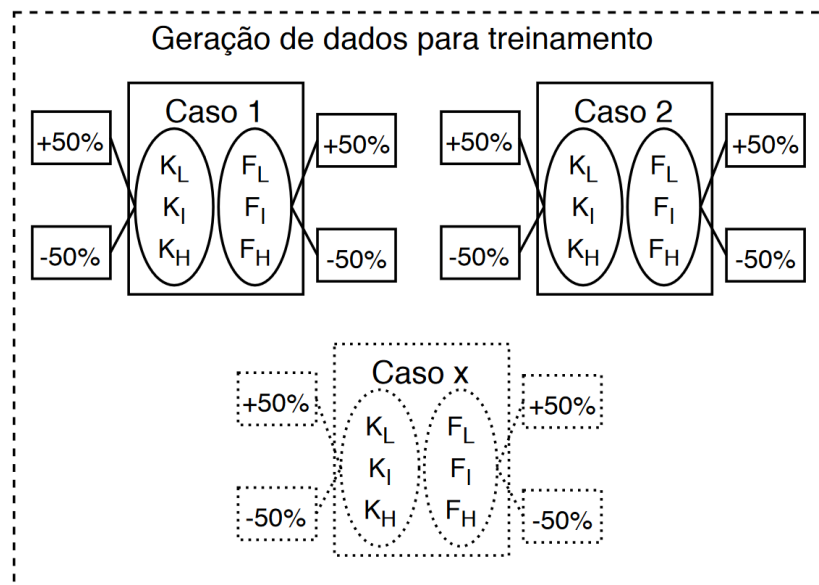
Fonte: elaborada pelo autor.

Primeiramente foi realizado a análise dos sinais de entrada, depois teste do número de *delays* e teste do número de camadas escondidas. Após encontrar uma forma em que a rede neural amortece as oscilações, um método para criação de dados para treinamento foi criado. Por fim, foi realizado o teste das funções de treinamento a fim de compará-las e utilizar a função com melhor performance. O Apêndice C apresenta o script da rede NARX no MATLAB®.

#### 4.4 GERAÇÃO DE DADOS PARA TREINAMENTO

O treinamento de uma rede neural é uma etapa muito importante. Ele deve garantir uma boa estabilidade em diferentes casos do sistema e ao mesmo tempo manter o banco de dados o menor possível, sem informações inúteis. Várias tentativas de treinamento foram exploradas neste trabalho com diferentes tempos de amostragem, número de amostras e casos. A forma de treinamento que obteve a melhor resposta em termos de amortecimento das oscilações foi utilizando um tempo de amostragem de 100 ms e criando dados com os parâmetros mostrados na Figura 20. Tanto a taxa de amostragem como esta metodologia para geração de dados para treinamento pode ser utilizada em outros problemas.

Figura 20 – Geração de dados para treinamento da rede NARX



Fonte: Elaborada pelo autor

Para cada ponto de operação otimizado via AG, foram realizadas quatro outras simulações alterando os seis parâmetros do PSS4b em  $\pm 50\%$ . Este método faz com que o banco de dados criado para treinar a rede neural fosse reduzido e que a rede neural consiga caracterizar os efeitos de cada ganho e frequência no sistema. Os dados de todos os quatro geradores foram incluídos

no banco de dados, desta forma, o controlador GA-NARX-PSS é o mesmo para todos os geradores.

O banco de dados para o treinamento da rede neural foi organizado em dois arquivos, chamados dados de entrada e dados de saída, conforme apresentado anteriormente pela Figura 18. Primeiramente os dados de entrada que são representados por uma matriz  $2 \times 40000$ , onde as variáveis são o desvio de velocidade do rotor e a saída do PSS4b. Os dados de saída são os ganhos do estabilizador e são concebidos como uma matriz  $6 \times 40000$ .

Com uma janela de dados  $u$  e amostras  $n$ , as matrizes podem ser representadas pelas equações (11) e (12) abaixo como:


$$\text{Matriz de Entrada} = \begin{bmatrix} V_{stab} n & \Delta\omega n \\ \vdots & \vdots \\ V_{stabx}(n+u) & \Delta\omega_x(n+u) \end{bmatrix} \quad (11)$$

$$\begin{array}{c} \text{Matriz de Saída} = \\ \left[ \begin{array}{cccccc} F_l n & K_l n & F_i n & K_i n & F_h n & K_{hn} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ F_{lx}(n+u) & K_{lx}(n+u) & F_{ix}(n+u) & K_{ix}(n+u) & F_{hx}(n+u) & K_{hx}(n+u) \end{array} \right] \end{array} \quad (12)$$

O número de camadas ocultas, neurônios e atrasos foram selecionados por uma abordagem de tentativa e erro. A topologia do NARX com a melhor resposta foi a que utilizou duas camadas ocultas com três neurônios cada e seis atrasos (TDL), como mostra a Figura 21. Os TDL são posicionados logo na entrada da arquitetura, sendo representados como 1:6 no diagrama.



Figura 21 – Topologia da rede NARX



Fonte: Elaborada pelo autor

#### 4.5 CONSIDERAÇÕES FINAIS

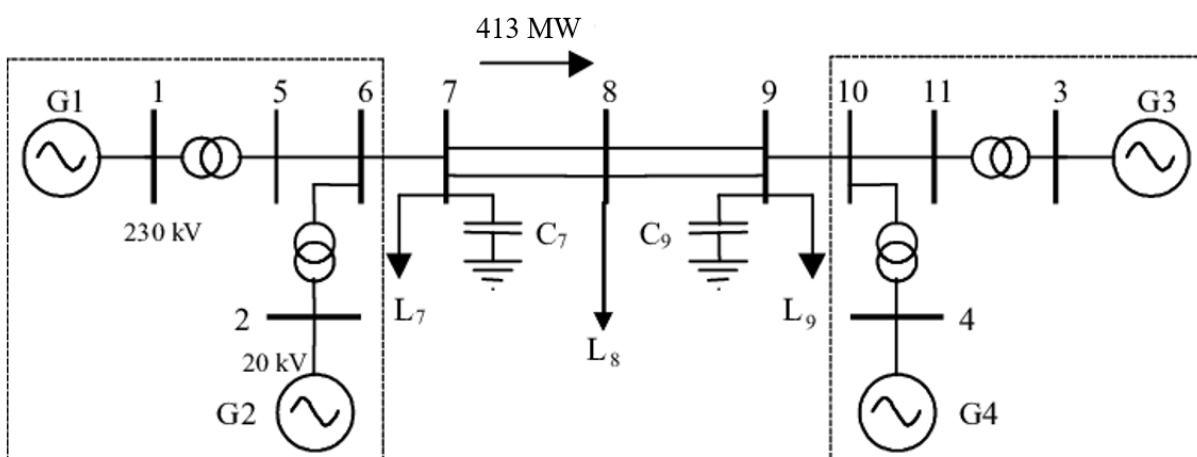
Este capítulo apresenta a metodologia proposta nesta tese. Primeiramente, a metodologia foi dividida entre a parte da simulação off-line e on-line. Na simulação off-line o AG é proposto como método de otimização de uma função multiobjetivo escalar. A rede neural NARX é apresentada em conjunto com uma proposta de geração de dados para treinamento desta. No próximo capítulo, os resultados obtidos são apresentados.

## 5 RESULTADOS OBTIDOS

### 5.1 SISTEMA BASE

O sistema base utilizado nesta tese é o sistema de duas áreas e quatro máquinas proposto por (KUNDUR, et al., 1994). Os dois sistemas de potência são controlados com áreas totalmente simétricas e conectados por duas linhas de transmissão. A Figura 22 apresenta o modelo de sistema simulado em um ambiente MATLAB/SIMULINK® com uma representação detalhada da dinâmica do sistema. Cada área é equipada com dois geradores síncronos idênticos de 20 kV/900 MVA. Os geradores usam reguladores de velocidade idênticos, turbinas, AVR e PSS. As cargas nas duas áreas são tais que a Área 1 exporta 413 MW para a Área 2. Mais detalhes desse sistema podem ser encontrados em (KUNDUR, et al., 1994).

Figura 22 – Sistema de duas áreas e quatro máquinas



Fonte: adaptada de (KUNDUR, 1994).

A perturbação utilizada para simular as oscilações do sistema mostrado na Figura 22 é uma falta trifásica para terra que ocorre durante 12 ciclos da frequência fundamental de 60 Hz (200 ms). A falta é aplicada à barra 8 da Figura 22. Essa falta é a que causa a oscilação transitória mais agravante por ser entre as duas linhas conforme explicado em (KUNDUR, 1994).

Os curtos-circuitos podem ser classificados como permanentes ou temporários. Os permanentes são irreversíveis, necessitando de conserto na rede para restabelecer o sistema. Já os curtos-circuitos temporários, são aqueles que ocorrem sem danos permanente. Após a atuação da proteção o sistema pode ser restabelecido automaticamente. Os curtos temporários são os que ocorrem com maior frequência (SATO; FREITAS, 2015). As faltas trifásicas equilibradas estão entre as menos comuns, mas causam as mais graves quedas de tensão.

A Tabela 1 mostra os cenários de teste do estudo de caso com diferentes cargas. O objetivo de usar uma carga pesada é obter um fluxo de energia da área 2 para a área 1 de modo que a dinâmica de ambos os sistemas mude muito, assim como na carga nominal e o fluxo de potência sendo da área 1 para a área 2. Esses testes dos cenários são usados posteriormente com a otimização do GA e o GA-NARX-PSS nas próximas sessões.

Tabela 1 – Cenários de teste (em MW e MVar)

Geradores	Carga Nominal		Carga Pesada Área 2		Carga Leve	
	P	Q	P	Q	P	Q
<b>G1</b>	700	90	320	-30	700	60
<b>G2</b>	700	120	700	-40	480	200
<b>G3</b>	720	80	1100	300	720	70
<b>G4</b>	700	80	900	330	700	40
<b>L1</b>	970	100	1067	110	870	90
		1760	1938	110	1580	
<b>L2</b>	100				90	

Fonte: Autor.

A Tabela 2 apresenta os parâmetros dos geradores no sistema base.

A Figura 23 apresenta o sistema descrito acima. O fluxo é rodado apenas uma vez antes do começo da simulação. Após o curto-circuito, os disjuntores A (localizado na barra 6) e B A (localizado na barra 10) são abertos fazendo com que o sistema entre em uma fase chamada de pós falta.

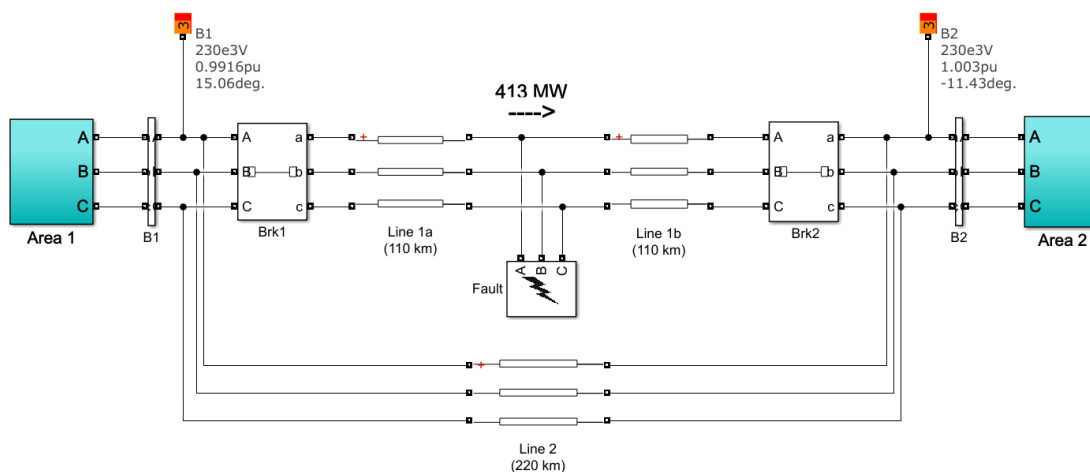
Tabela 2 – Parâmetros geradores do sistema base

Ger.	$X_{d(\Omega)}$	$X_{q(\Omega)}$	$X'_{d(\Omega)}$	$X'_{q(\Omega)}$	$X''_{d(\Omega)}$	$X''_{q(\Omega)}$	$T'_{do(s)}$	$T''_{do(s)}$	$X_l(\Omega)$	$T'_{qo(s)}$	$T''_{qo(s)}$	$H(s)$	D	$R_a(\Omega)$
1	1,8	1,7	0,3	0,2	0,5	0,2	8,0	0,0	0,2	0,4	0,4	6,5	0	0,0025
2	1,8	1,7	0,3	0,2	0,5	0,2	8,0	0,0	0,2	0,4	0,4	6,5	0	0,0025
3	1,8	1,7	0,3	0,2	0,5	0,2	8,0	0,0	2,4	0,4	0,4	1,6	0	0,0025
4	1,8	1,7	0,3	0,2	0,5	0,2	8,0	0,0	0,2	0,4	0,4	6,5	0	0,0025

Fonte: Autor.

O ponto de operação acaba se alterando e nos gráficos dos resultados pode-se perceber uma mudança no ângulo de carga dos geradores e da tensão terminal neste novo ponto de operação.

Figura 23 – Sistema de duas áreas e quatro máquinas utilizado



Fonte: adaptada de (KUNDUR et al., 1994).

## 5.2 OTIMIZAÇÕES VIA ALGORITMO GENÉTICO

Nesta tese, a otimização dos parâmetros do estabilizador foi implementada utilizando o MATLAB em um Intel Core i5-9600K e 32 Gb de RAM com o sistema operacional Windows 10. Cada otimização do AG leva menos de cinco horas consumindo um núcleo da CPU. Os índices ISE, IAE, ITSE e ITSE foram comparados com a função multiobjetivo proposta no capítulo anterior, cujos resultados são mostrados na Tabela 3. Os primeiros parâmetros testados com AG vêm da função seleção por torneio, mutação e cruzamento.

Tabela 3 – Resultados do AG com sistema com carga nominal e diferentes tipos de funções objetivos

<b>Função Objetivo</b>	<b>Valor</b>
<b>ISE</b>	0,66
<b>IAE</b>	0,39
<b>ITSE</b>	0,53
<b>ITAE</b>	0,48
<b>Multiobjetivo</b>	0,32

Fonte: Autor.

Cada função objetivo da Tabela 3 foi calculada em uma otimização diferente, então a resposta encontrada com a multiobjetivo corresponde a uma otimização única. Sendo assim, este dos índices não tem correlação direta com o valor encontrado pela função multiobjetivo.

Inúmeras otimizações foram aplicadas empregando diferentes parâmetros para seleção, cruzamento, migração, número de população e gerações na recuperação do sistema de potência. Parâmetros como intervalo da população inicial, população total e o número de gerações não resultaram em grandes mudanças no resultado do amortecimento das oscilações. O parâmetro que mais impactou a função objetivo foi a mutação. A Tabela 4 apresenta os melhores resultados e modificações nos parâmetros de mutação do AG.

Tabela 4 – Melhores resultados com o AG com modificação dos parâmetros de mutação

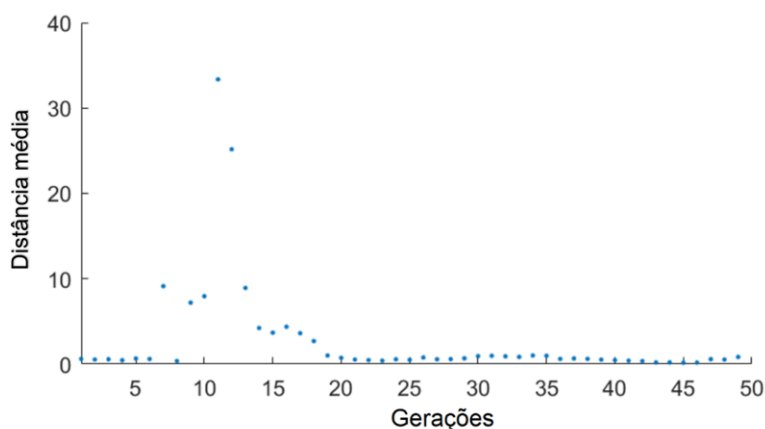
<b>Parâmetro modificado do AG</b>	<b>Valor</b>	<b>Pop. Inicial.</b>	<b>Obj. Func.</b>	<b>Pop .</b>	<b>Ger.</b>
	-	0-100	0,32	100	50
<b>Mutação dependente da restrição</b>	-	0-200	0,52	100	50
<b>Mutação Gaussiana</b>	1.0	0-100	0,40	100	50
<b>Mutação viavelmente adaptável</b>	-	0-100	0,52	100	50
	0,01	0-100	0,77	100	50
	0,0105	0-200	<b>0,15</b>	100	50
<b>Mutação uniforme</b>	0,05	0-100	0,77	100	50
	0,75	0-100	0,43	100	50
	0,1	0-100	0,50	100	50

Fonte: Autor.

A Figura 24 apresenta a distância média entre os indivíduos da melhor otimização encontrada com o AG com mutação uniforme em 0,0105.


A Figura 25 apresenta a função de seleção entre os indivíduos da melhor otimização encontrada com o AG com mutação uniforme em 0,0105.

Figura 24 – Distância média entre os indivíduos da melhor otimização encontrada com o AG (mutação uniforme 0,0105)



Fonte: Autor.

Figura 25 – Função de seleção da melhor otimização encontrada com o AG (mutação uniforme 0,0105)

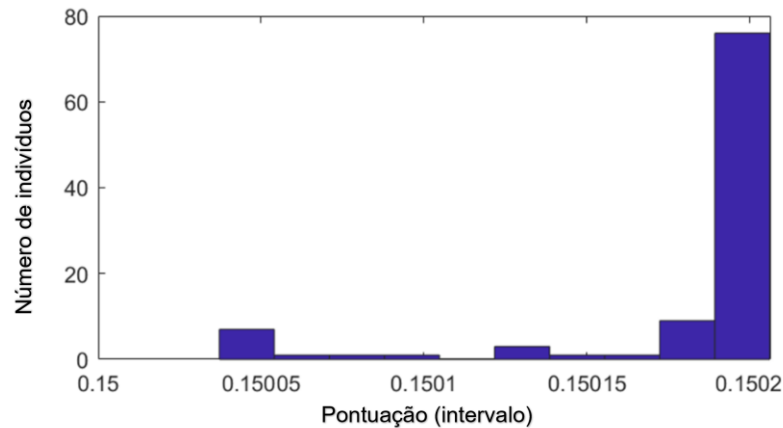


Fonte: Autor.

A Figura 26 apresenta a função de seleção entre os indivíduos da melhor otimização encontrada com o AG com mutação uniforme em 0,0105.

A função de mutação que obteve os melhores resultados foi a uniforme. O distúrbio é um curto-circuito trifásico de 200 ms, o qual é o pior cenário para o amortecimento das oscilações.

Figura 26 – Histograma da função objetivo indivíduos da melhor otimização encontrada com o AG (mutação uniforme 0,0105)



Fonte: Autor.

A Tabela 5 apresenta os ganhos do PSS obtidos com o AG com diferentes cenários de carga e do método de alocação de polos.


Tabela 5 – Ganhos utilizados para o PSS4b

<b>Ganhos PSS simplificados</b>	<b>AG Carga Nominal</b>	<b>AG Carga Pesada Área 2</b>	<b>AG Carga Leve</b>	<b>Ganhos Alocação de Polos</b>
<b>Fi</b>	0,077	0,71	0,64	0,2
<b>Ki</b>	97,23	68,63	44,57	30
<b>FI</b>	2,48	15,97	32,73	1,25
<b>KI</b>	87,85	96,79	98,01	40
<b>F<sub>H</sub></b>	16,87	52,34	52,34	12
<b>K<sub>H</sub></b>	82,68	66,48	71,96	160

A Figura 27 apresenta os resultados da melhor otimização encontrada com o AG e parâmetro de mutação uniforme de 0,0105. O primeiro gráfico representa a tensão das barras B1 e B2 (pu), enquanto o segundo gráfico apresenta o fluxo de potência entre as barras (MW).

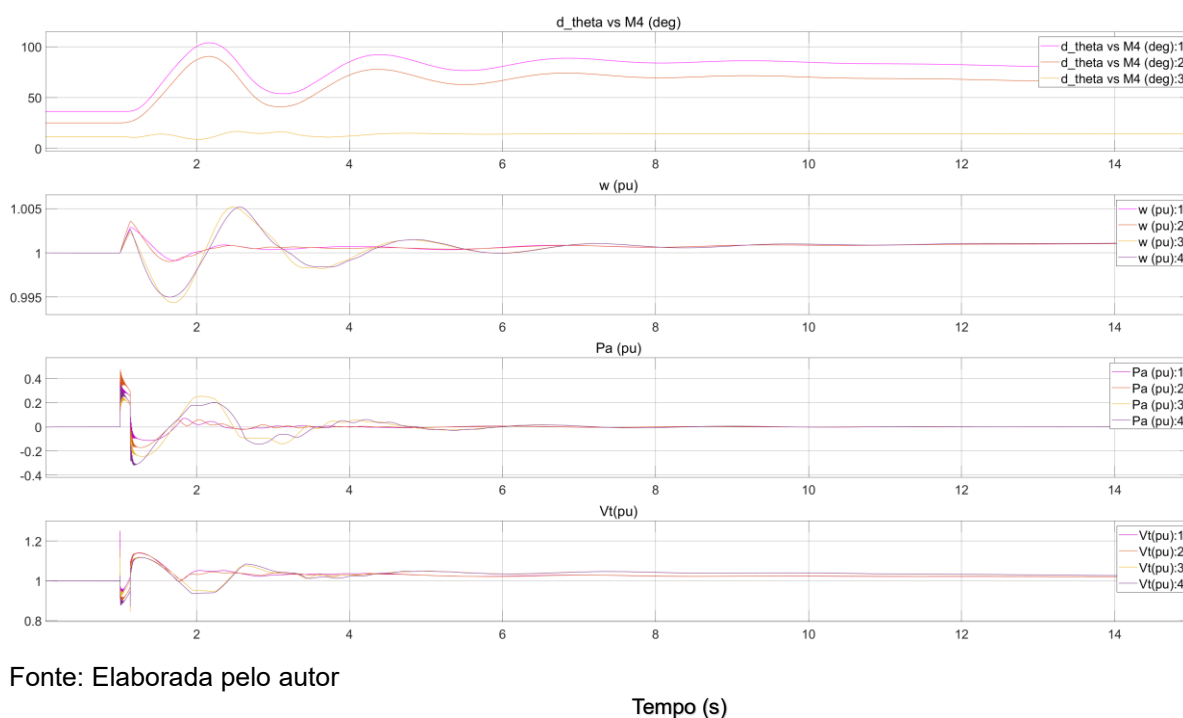
A Figura 28 apresenta o resultado da otimização detalhada por gerador com o ângulo de carga, velocidade, potência acelerante e tensão terminal, todos valores em PU.

Figura 27 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms.



Fonte: Elaborada pelo autor

Figura 28 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms, por gerador.




Fonte: Elaborada pelo autor

Tempo (s)



A Figura 29 apresenta a saída do PSS e o valor excitação por gerador. A Figura 30 e Figura 31 apresentam a parametrização do PSS com o método de alocação de polos, sendo possível comparar a otimização do AG esta abordagem.


Figura 29 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms, saída PSS e excitação.



Fonte: Elaborada pelo autor

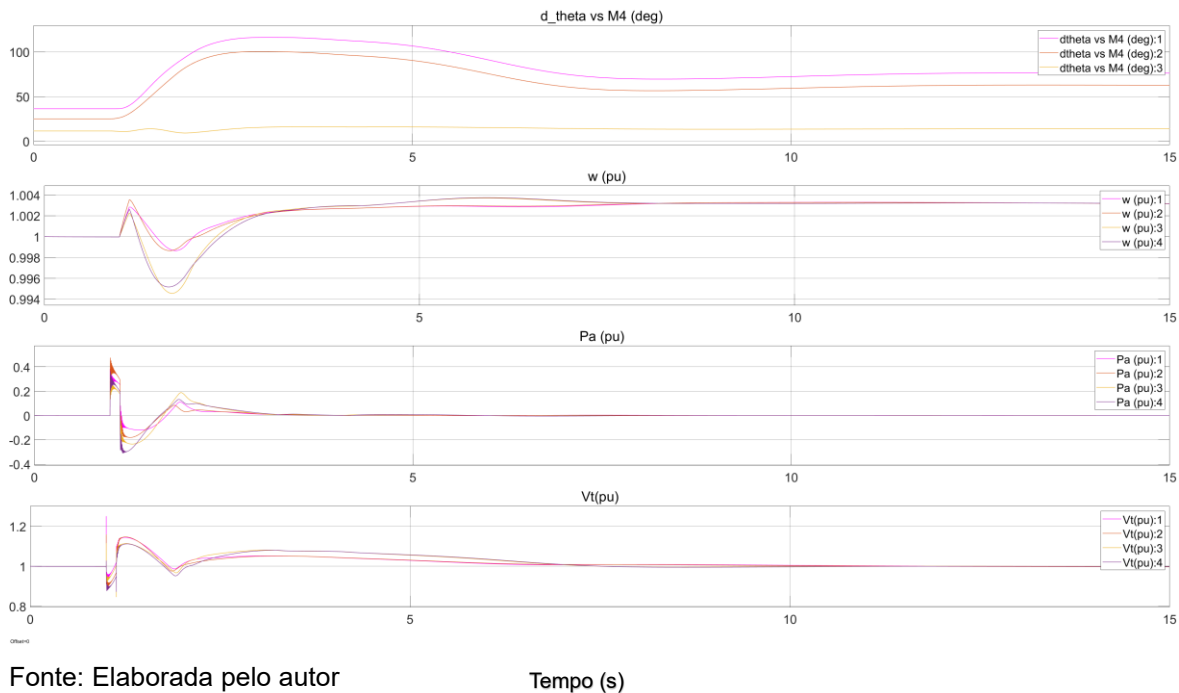
Tempo (s)

Figura 30 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 200 ms.




Fonte: Elaborada pelo autor

Figura 31 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 200 ms, por gerador.



A Figura 32 apresenta o valor da saída do bloco PSS4B em cada gerador ( $V_{stab}$ ) e o valor excitação por gerador, a qual representa a saída do AVR em conjunto com o estabilizador.

Figura 32 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 200 ms, saída PSS e excitação.



Os ganhos da otimização do AG têm valores mais altos do que o método de alocação de polos (Tabela 5), o que fica perceptível nos resultados com oscilações mais agressivas nos gráficos do AG.

As Figura 33 e Figura 34 mostram os resultados para um maior tempo de curto-circuito na barra 8 do sistema, agora em 260 ms. A otimização AG reduz a oscilação de potência.


No método de alocação de polos o sistema perde o sincronismo com o novo tempo de curto-circuito, o que pode ser verificado nas Figura 35 e Figura 36.

Os resultados anteriores foram considerados com um novo ponto de operação do sistema que é o caso quando os disjuntores são abertos e as áreas 1 e 2 não ficam mais interligadas.

As Figura 37 e Figura 38 apresentam o resultado da otimização com o AG considerando que o sistema volte a ser interligado após o curto-circuito.


A fim de obter mais dados para o treinamento NARX e garantir uma boa otimização em todos os casos, as Figura 39, Figura 40, Figura 41 e Figura 42 mostram os resultados da otimização de GA com diferentes níveis de carga no sistema.

Figura 33 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 260 ms.



Fonte: Elaborada pelo autor


Figura 34 – Melhor otimização com o AG para carga nominal e tempo de curto-circuito de 260 ms, resultado por geradores.



Fonte: Elaborada pelo autor


Tempo (s)

Figura 35 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 260 ms.




Fonte: Elaborada pelo autor

Figura 36 – Parametrização do PSS via alocação de polos com carga nominal e tempos de circuito-circuito 260 ms, por gerador.




Fonte: Elaborada pelo autor

Figura 37 – Otimização do AG com as áreas interligadas após o distúrbio, 200 ms de curto-circuito




Fonte: Elaborada pelo autor

Figura 38 – Otimização do AG com as áreas interligadas após o distúrbio, 200 ms de curto-circuito




Fonte: Elaborada pelo autor

Figura 39 – Otimização do AG para 90% da carga, com tempo de curto-circuito de 200 ms.




Fonte: Elaborada pelo autor

Figura 40 – Otimização do AG para 90% da carga, com tempo de curto-circuito de 200 ms, resultados por gerador.




Fonte: Elaborada pelo autor

Figura 41 – Otimização do AG para 95% da carga, com tempo de curto-circuito de 200 ms.



Fonte: Elaborada pelo autor

Figura 42 – Otimização do AG para 95% da carga com tempo de curto-circuito de 200 ms, resultado por gerador.



Fonte: Elaborada pelo autor

### 5.3 RESULTADOS AG-NARX-PSS

A Tabela 6 apresenta os resultados de desempenho, desempenho de treinamento e desempenho do teste para as diferentes funções de treinamento estudadas. Todos os índices são comparados com o critério de erro médio quadrático, então quanto menor o valor melhor é a resposta da função de treinamento.

O melhor resultado do GA-NARX-PSS foi o método de *bayesian Regulation backpropagation*, mas não muito distante de outras funções de treinamento, como: *RPROP backpropagation* e *scaled conjugate gradient backpropagation*.

A Figura 43 apresenta os resultados de desempenho encontrados com a função de treinamento *bayesian Regulation backpropagation*.

A Figura 44 apresenta os resultados de desempenho encontrados com a função de treinamento *bayesian Regulation backpropagation*:




Tabela 6 – Resultado das funções de treinamento para a NARX

Método de Treinamento	Performance	Treino de Performance	Teste Performance
<i>Levenberg-Marquardt backpropagation</i>	0,7091	0,7576	0,1114
<b><i>Bayesian Regulation backpropagation</i></b>	<b>0,5788</b>	<b>0,6092</b>	<b>1,95e-04</b>
<i>FGS quasi-Newton backpropagation</i>	1,4418	1,5099	0,3456
<i>Gradient descent with adaptive lr</i>	1,6091	1,6747	1,0177
<i>RPROP backpropagation</i>	0,5846	0,6495	9,74e-04
<i>Scaled conjugate gradient backpropagation</i>	0,5794	0,6437	4.57e-04


Fonte: Autor.

Figura 43 – Melhor validação de desempenho do método bayesian Regulation backpropagation



Fonte: Elaborada pelo autor


Figura 44 – Resultado do Gradient, Mu e validação bayesian Regulation backpropagation



Fonte: Elaborada pelo autor


A seguir, são apresentados os resultados obtidos para cada caso simulado com a metodologia AG-NARX-PSS. As Figura 45 e Figura 46 apresentam os resultados da metodologia para carga nominal, com tempo de curto-circuito de 200 ms.

Figura 45 – AG-NARX-PSS carga nominal e tempo de curto-circuito 200 ms



Fonte: Elaborada pelo autor

Figura 46 – AG-NARX-PSS carga nominal e tempo de curto-circuito 200 ms, resultados por gerador




Fonte: Elaborada pelo autor

Tempo (s)


As Figura 47 e Figura 48 apresentam os resultados da metodologia para carga pesada com 200 ms de tempo de curto-circuito.

Figura 47 – AG-NARX-PSS carga pesada e tempo de curto-circuito 200 ms



Fonte: Elaborada pelo autor


Figura 48 – AG-NARX-PSS carga pesada e tempo de curto-circuito 200 ms, por gerador



Fonte: Elaborada pelo autor

As Figura 49 e Figura 50 apresentam os resultados da metodologia para carga leve, 200 ms de tempo de curto-circuito.


Figura 49 – AG-NARX-PSS carga leve e tempo de curto-circuito 200 ms



Fonte: Elaborada pelo autor

Tempo (s)


Figura 50 – AG-NARX-PSS carga leve e tempo de curto-circuito 200 ms, por gerador



Fonte: Elaborada pelo autor


As Figura 51 e Figura 52 apresentam os resultados da metodologia para carga leve, 100ms de tempo de curto-circuito.

Figura 51 – AG-NARX-PSS carga nominal e tempo de curto-circuito 100 ms



Fonte: Elaborada pelo autor


Figura 52 – AG-NARX-PSS carga nominal e tempo de curto-circuito 100 ms, por gerador



Fonte: Elaborada pelo autor

A Figura 53 apresenta as alterações de ganhos que a rede neural efetua durante o distúrbio no primeiro gerador com carga nominal e tempo de curto-circuito 200 ms.

Figura 53 – Saída do AG-NARX-PSS para o  $G_1$ , carga nominal e tempo de curto-circuito 200 ms




Fonte: Elaborada pelo autor

## 5.4 OTIMIZAÇÕES VIA WOA

O Apêndice E apresenta o WOA. A implementação completa do WOA utilizada pode ser encontrada em (MIRJALILI, 2016), 150 baleias foram usadas com 50 interações e a otimização levou cerca de 4 horas. A Figura 54 apresenta o histórico da busca com o WOA.

Os pontos em preto no gráfico representam as soluções encontradas em cada interação pela função multiobjetivo (mesma utilizado com o AG), enquanto a linha azul apresenta a média da função multiobjetivo por interação.

Figura 54 – Histórico da busca com o WOA




Fonte: Elaborada pelo autor

## 5.5 COMPARAÇÃO DA METODOLOGIA

Com o intuito de comparar o AG-NARX-PSS com outras metodologias, as Figura 55, Figura 56 e Figura 57 apresentam a comparação entre a abordagem aqui proposta com o AG usando parâmetros fixos e otimização via WOA.


Nos três casos, é possível observar que o GA-NARX-PSS tem uma resposta superior. Em especial, a Figura 57 a qual apresenta o resultado com um tempo de curto-circuito maior onde apenas a rede NARX consegue amortecer as oscilações.

Figura 55 – Comparação entre AG-NARX-PSS, WOA e AG com parâmetros fixo com carga leve e tempo de curto-circuito em 200 ms



Fonte: Elaborada pelo autor


Figura 56 – Comparação entre AG-NARX-PSS, WOA e AG com parâmetros fixo com carga pesada e tempo de curto-circuito em 200 ms



Fonte: Elaborada pelo autor



Figura 57 – Comparação entre AG-NARX-PSS, WOA e AG com parâmetros fixo com carga nominal e tempo de curto-circuito em 400 ms



## 5.6 CONSIDERAÇÕES FINAIS

Este capítulo primeiramente apresenta o sistema base utilizado. Após, foram relatados os resultados da otimização via AG, a qual foi comparada com o método de alocação de polos e demonstrou melhorias significativa principalmente quando comparado com faltas com tempos de curto-circuito maiores. Em seguida, foram apresentados os resultados da rede NARX e comparados com WOA e AG com ganhos fixos. Em todos os casos a RNA teve uma resposta superior em comparação com os outros métodos. Na próxima seção serão apresentadas as conclusões da tese.

## 6 CONCLUSÕES

A presente tese aborda o amortecimento de oscilações em sistemas de potência. Tais sistemas operam muito próximos aos seus limites e a dinâmica dos sistemas de energia, com elementos variáveis no tempo e não lineares tornando muito complexo se poder garantir uma operação estável. Grandes perturbações como curtos-circuitos, chaveamento de linhas, desconexão de gerador e perda de grandes blocos de carga podem acarretar oscilações de potência. Elas são geralmente observadas em sistemas cujas linhas elétricas fazem parte de conexões fracas, linhas mal dimensionadas ou sobrecarga nos terminais da rede.

Esta tese propõe uma metodologia AG-NARX-PSS para se contrapor a este fenômeno. O método de otimização via AG com função multiobjetivo é utilizado como um pré-cálculo para os parâmetros do IEEE PSS4B em uma ampla faixa de condições de carga e com diferentes funções do AG. A NARX fornece parâmetros para o PSS, os quais foram otimizados com um banco de dados obtido via AG. Este trabalho foi aplicado no ajuste do estabilizador em um sistema de duas áreas e quatro máquinas.

Para mostrar que a abordagem do AG é adequada, primeiramente, uma comparação foi realizada com o método de alocação de polos em diferentes casos de carga e de tempo de curto-circuito. Os resultados mostram que a otimização do AG apresenta resultados superiores quando comparado ao método de alocação de polos.

Uma nova técnica de geração de dados para treinamento de RNA é aqui proposta, a qual necessita de apenas quatro pontos de operação para que a rede neural reconheça os padrões do sistema de potência. Esta técnica pode ser utilizada para qualquer outro controlador neural e planta. Apesar de haver trabalhos sobre o tema, eles não abordam a rede NARX no problema do estabilizador a qual apresenta algumas vantagens em relação as outras topologias. Nenhum trabalho utiliza estabilizadores consolidados por normativas como o IEEE PSS2b e IEEE PSS4b fazendo com que sua aplicação fique deixada de lado pelos fabricantes. Outros trabalhos utilizam como validação apenas sistemas de um gerador na barra infinita deixando dúvidas sobre a capacidade dos controladores.

Os resultados das simulações no estudo de caso desta tese demonstraram que o GA-NARX-PSS apresentou melhores efeitos no amortecimento de oscilações decorrentes das perturbações comparado com outras técnicas de ajuste de estabilizadores apresentadas na literatura. Observou-se que o GA-NARX-PSS amorteceu as oscilações provocadas por curto-circuito com tempo de duração maiores que o suportado pelo PSS sintonizado, tanto com otimização via AG como com o algoritmo WOA.

## 6.1 TRABALHOS FUTUROS

Como trabalho futuro pode-se sugerir:

- A utilização do AG-NARX-PSS em uma usina hidrelétrica com o intuito de validar a metodologia proposta em uma planta real. O projeto utilizaria um controlador lógico programável (CLP) comercial o qual deve ser capaz de medir as grandezas elétricas do gerador em meio ciclo da frequência operacional;
- Emprego da metodologia de geração de dados para treinamento da RNA para controle de plantas com geração renovável;
- Aplicação da metodologia no AVR e regulador de velocidade, além do estabilizador.

## 6.2 PUBLICAÇÕES

Produção científica:

Publicação em Periódicos Qualis A:

CARBONERA, L. F. B., BERNARDON, D. P., KARNIKOWSKI, D. C., FARRET, F. A. **The nonlinear autoregressive network with exogenous inputs (NARX) neural network to damp power system oscillations.** International Transactions on Electrical Energy Systems, p. e12538, 2020.

MAGNUS, D. M., CARBONERA, L. F. B., PFITSCHER, L. L., FARRET, F. A., BERNARDON, D. P., TAVARES, A. A. **An Educational Laboratory Approach for Hybrid Project-Based Learning of Synchronous Machine Stability and Control: A Case Study.** IEEE Transactions on Education, 63(1), 48-55, 2020.

## Publicação em Revistas:

CARBONERA, L. F. B., GIASSI, M. A., SALVARO, P. V. **Aprendizagem Baseada no Problema do Carregador de Baterias Inteligente.** Revista Tecnologias na Educação Art5 vol.24 Edição Temática VII junho 2018, ISSN: 1984-4751.

D. Magnus, L. Carbonera, L. Pfitscher, D. Bernardon, A. Tavares and C. Scharlau, **"Experimental and Educational Platform for Operation Tests and Parameterization of Power System Regulators and Stabilizers,"** in *IEEE Latin America Transactions*, vol. 17, no. 01, pp. 54-62, January 2019, doi: 10.1109/TLA.2019.8826695.

## Publicação em Congressos:

MAGNUS, D. M., CARBONERA, L. F. B., PFITSCHER, L. L., BERNARDON, D. P., TAVARES, A. A. **Desenvolvimento de uma bancada didática para controle de tensão de geradores síncronos.** COBENGE'2017 – XLV Congresso Brasileiro de Educação em Engenharia. Data/Local: 26 a 29 de setembro de 2017. Joinville – Santa Catarina.

DAZZI, L. K., BERNARDON, D. P., CARBONERA, L. F. B. **Sistema SCADA para Supervisão de Bancada Didática para Controle de Gerador Síncrono.** SEPOC 2017 – 10º Seminário de Eletrônica de Potência e Controle. Data/Local: 22 a 25 de outubro de 2017. Santa Maria – Rio Grande do Sul.

CARBONERA, L. F. B., GIASSI, M. A., SALVARO, P. V. **Aprendizagem Baseada em Problemas no Curso de Engenharia Elétrica.** SITED'2018 – II Simpósio Ibero-Americano de Tecnologias Educacionais. Data/Local: 11 a 13 de abril de 2018. Araranguá – Santa Catarina.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

ALVAREZ MAMANI, Ana Beatriz et al. **Utilização de redes neurais no controle da velocidade de um veículo experimental.** 2004.

ANSARI, J. A. et al. **Selection of Suitable Feedforward Neural Network Based Power System Stabilizer for Robust Excitation Control System.** In: 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe). IEEE, 2018. p. 1-6.

ANSARI, Jamshed A. et al. **Selection of Suitable Feedforward Neural Network Based Power System Stabilizer for Robust Excitation Control System.** In: 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe). IEEE, 2018. p. 1-6.

BARREIROS, José AL et al. **A neural power system stabilizer trained using local linear controllers in a gain-scheduling scheme.** International Journal of Electrical Power & Energy Systems, v. 27, n. 7, p. 473-479, 2005.

BHUTTO, Darya Khan; ANSARI, Jamshed; ZAMEER, Halar. **Implementation of AI Based Power Stabilizer Using Fuzzy and Multilayer Perceptron In MatLab.** In: 2020 3rd International Conference on Computing, Mathematics and Engineering Technologies (iCoMET). IEEE, 2020. p. 1-8.

BUTTI, Dasu; MANGIPUDI, Siva Kumar; RAYAPUDI, Srinivasa Rao. **An improved whale optimization algorithm for the design of multi-machine power system stabilizer.** International Transactions on Electrical Energy Systems, v. 30, n. 5, p. e12314, 2020.

CAMPOS, M. M de e SAITO, K. **Sistemas inteligentes em controle e automação de processos.** Rio de Janeiro: Editora Ciência Moderna Ltda, 2004.

CHATURVEDI, D. K.; MALIK, O. P. **Generalized neuron-based adaptive PSS for multimachine environment.** IEEE Transactions on power systems, v. 20, n. 1, p. 358-366, 2005.

CHEN, Yue; ZHANG, Zhenya. **Analysis of outrigger numbers and locations in outrigger braced structures using a multiobjective genetic algorithm.** The Structural Design of Tall and Special Buildings, v. 27, n. 1, p. e1408, 2018.

CHOW, Joe H.; SANCHEZ-GASCA, Juan J. **Power System Dynamics and Simulation.** 2020.

COURY, D. V.; JORGE, D. C. **The backpropagation algorithm applied to protective relaying.** In: International Conference on Neural Networks. Houston, Texas, EUA: [s.n], 1997. V. 1, p. 105-110.

DEB, Kalyanmoy. **Multi-objective optimization using evolutionary algorithms.** John Wiley & Sons, 2001.

DIACONESCU, E. **The use of NARX neural networks to predict chaotic time series.** Wseas Transactions on computer research, v. 3, n. 3, p. 182-191, 2008.

FIORI, E. M. G. **Identificação de sistemas não-lineares utilizando redes neurais artificiais.** Rio Grande do Sul, 2007.

FORTES, E. V.; ARAUJO, P. B. de; MACEDO, L. H. **Coordinated tuning of the parameters of PI, PSS and POD controllers using a specialized Chu-Beasley's genetic algorithm.** Electric Power Systems Research, v. 140, p. 708-721, 2016.

GANDHI, P. R.; JOSHI, S. K. **Soft Computing Techniques for Designing of Adaptive Power System Stabilizer.** In: 2019 IEEE Milan PowerTech. IEEE, 2019. p. 1-6.

GAUTAM, Durga; VITTAL, Vijay; HARBOUR, Terry. **Impact of increased penetration of DFIG-based wind turbine generators on transient and small signal stability of power systems.** IEEE Transactions on power systems, v. 24, n. 3, p. 1426-1434, 2009.

GOLDBOGEN, J. A. et al. **Integrative approaches to the study of baleen whale diving behavior, feeding performance, and foraging ecology.** BioScience, v. 63, n. 2, p. 90-100, 2013.

GOLEIJANI, S, AMELI, MT. **Neural network-based power system dynamic state estimation using hybrid data from SCADA and phasor measurement units.** Int Trans Electr Energ Syst. 2018; 28:e2481. <https://doi.org/10.1002/etep.2481>.

HAYKIN, S.; **Neural networks and learning machines.** 3<sup>a</sup> Ed. United States of America, New Jersey: Pearson, 2009.

HOF, P. R.; VAN DER GUCHT, E. **Structure of the cerebral cortex of the humpback whale, *Megaptera novaeangliae* (Cetacea, Mysticeti, Balaenopteridae).** The Anatomical Record: Advances in Integrative Anatomy and Evolutionary Biology: Advances in Integrative Anatomy and Evolutionary Biology, v. 290, n. 1, p. 1-31, 2007.

HUANG, Garng M.; WANG, Wenzong; AN, Jun. **Stability issues of smart grid transmission line switching.** IFAC Proceedings Volumes, v. 47, n. 3, p. 7305-7310, 2014.

**IEEE Guide for Synchronous Generator Modeling Practices and Applications in Power System Stability Analyses.** IEEE Std 1110-2002 (Revision of IEEE Std 1110-1991 [2003]): 1–72.

**IEEE Recommended Practice for Excitation System Models for Power System Stability Studies,**" in IEEE Std 421.5-2005 (Revision of IEEE Std 421.5-1992), vol., no., pp.1-93, 21 April 2006 doi: 10.1109/IEEESTD.2006.99499.

IEEE **Standard Definitions for Excitation Systems for Synchronous Machines**," in IEEE Std 421.1-2007 (Revision of IEEE Std 421.1-1986) , vol., no., pp.1-33, 15 July 2007, doi: 10.1109/IEEESTD.2007.385319.

IEEE Subsynchronous resonance working group, **"Second benchmark model for computer simulation of subsynchronous resonance,"** *IEEE Transactions on Power Apparatus and Systems*, Vol. PAS-104, No. 5, 1985, pp. 1057-1066.

ISBEIH, Younes J. et al.  **$H^\infty$  mixed-sensitivity robust control design for damping low-frequency oscillations with DFIG wind power generation.** *IET Generation, Transmission & Distribution*, v. 13, n. 19, p. 4274-4286, 2019.

JHANG, S. et al. **ANN Control for Damping Low-frequency Oscillation using Deep learning.** In: 2018 Australasian Universities Power Engineering Conference (AUPEC). IEEE, 2018. p. 1-4.

KAHOULI, O.; ALSHAMMARI, B.; DHOUIB, B. **Application of ANN and ANFIS techniques for PSS tuning in a multimachine power system.** In: 2019 16th International Multi-Conference on Systems, Signals & Devices (SSD). IEEE, 2019. p. 435-440.

KAMALASADAN, S.; SWANN, G. D.; YOUSEFIAN, R. **A novel system-centric intelligent adaptive control architecture for power system stabilizer based on adaptive neural networks.** *IEEE Systems Journal*, v. 8, n. 4, p. 1074-1085, 2014.

KISHOR, Nand et al. **Controller design with model identification approach in wide area power system.** *IET Generation, Transmission & Distribution*, v. 8, n. 8, p. 1430-1443, 2014.

KUMAR, PK Arun et al. **Neural network tuned fuzzy logic power system stabilizer design for SMIB.** In: 2016 2nd International Conference on Contemporary Computing and Informatics (IC3I). IEEE, 2016. p. 446-451.

KUNDUR, Prabha; BALU, Neal J.; LAUBY, Mark G. **Power system stability and control.** New York: McGraw-hill, 1994.

LALA, J. A. O.; GALLARDO, C. F. **Adaptive Tuning of Power System Stabilizer Using a Damping Control Strategy Considering Stochastic Time Delay.** *IEEE Access*, v. 8, p. 124254-124264, 2020.

LEON, A. E. **Multi-machine power system stability improvement using an observer-based nonlinear controller.** *Electric Power Systems Research*, pg. 204 – 214, 2012.

LI, Xiao-Ming et al. **A neural power system stabilizer of DFIGs for power system stability support.** *International Transactions on Electrical Energy Systems*, v. 28, n. 6, p. e2547, 2018.

MAGANGANE, Luyolo N.; FOLLY, Komla A. **Neural networks for designing an automatic voltage regulator of a synchronous generator.** In: 2013 Africon. IEEE, 2013. p. 1-5.

MASROB, M. A. et al. **Design of a simple neural network stabilizer for a synchronous machine of power system via MATLAB/Simulink**. In: 2017 IEEE International Electric Machines and Drives Conference (IEMDC). IEEE, 2017. p. 1-6.

MENCO, Carlos Andres Lazaro et al. **Método para detecção de oscilação de potência no domínio do tempo**. 2018. Tese de Doutorado. Universidade Federal de Santa Maria.

MILLA, F.; DUARTE-MERMOUD, M. A. **Predictive optimized adaptive PSS in a single machine infinite bus**. ISA transactions, v. 63, p. 315-327, 2016.

MIRJALILI, S.; LEWIS, A.. **The whale optimization algorithm**. Advances in engineering software, v. 95, p. 51-67, 2016.

MOEINI, A. et al. **Synchronous Machine Stability Model, an Update to IEEE Std 1110-2002 Data Translation Technique**. In: 2018 IEEE Power & Energy Society General Meeting (PESGM). IEEE, 2018. p. 1-5.

MOHAMMADI, M.; GHADIMI, N.. **Optimal location and optimized parameters for robust power system stabilizer using honeybee mating optimization**. Complexity, v. 21, n. 1, p. 242-258, 2014.

NARENDRA, K. S.; PARTHASARATHY, Kannan. **Learning automata approach to hierarchical multiobjective analysis**. IEEE Transactions on systems, man, and cybernetics, v. 21, n. 1, p. 263-272, 1991.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Requisitos técnicos mínimos para conexão à rede básica: Submódulo 3.6**. Rio de Janeiro, RJ, Brasil, Julho de 2008.

PRIDDY, K. L.; KELLER, P. E. **Artificial neural networks: an introduction**. SPIE press, 2005.

RANA, M. J.; SHAHRIAR, M. S.; SHAFIULLAH, Md. **Levenberg–Marquardt neural network to estimate UPFC-coordinated PSS parameters to enhance power system stability**. Neural Computing and Applications, v. 31, n. 4, p. 1237-1248, 2019.

SAHU, P. R.; HOTA, P. K.; PANDA, S.. **Modified whale optimization algorithm for coordinated design of fuzzy lead-lag structure-based SSSC controller and power system stabilizer**. International Transactions on Electrical Energy Systems, v. 29, n. 4, p. e2797, 2019.

SATO, F.; FREITAS, W.. **Análise de curto-circuito e princípios de proteção em sistemas de energia elétrica**. Rio de Janeiro: Elsevier, 2015.

SANDVIK, Peter Micah et al. **Impurity detection in combustor systems**. U.S. Patent n. 8,505,303, 13 ago. 2013.

SANTRA, Swapan; PAUL, Subrata. **PSO based robust power system stabilizer design using  $H^\infty$  loop shaping technique**. In: 2016 International



Conference on Computer, Electrical & Communication Engineering (ICCECE). IEEE, 2016. p. 1-6.

SBEIH, Younes J. et al. **H $\infty$  mixed-sensitivity robust control design for damping low-frequency oscillations with DFIG wind power generation.** IET Generation, Transmission & Distribution, v. 13, n. 19, p. 4274-4286, 2019.

SHAKARAMI, M.R. DAVOUDKHANI, I. Faraji. **“Wide-area power system stabilizer design based on Grey Wolf Optimization algorithm considering the time delay”** Electric Power Systems Research, Vol. 133, Apr 2016, pp 149-159.

SHAYEGHI, H et al. **Simultaneous optimal placement and parameter-tuning of SVC, TCSC and PSS using Honey-Bee Mating Optimization.** In: 2013 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC). IEEE, 2013. p. 1-5.

SHOJAEI, Ali Asghar; OTHMAN, Mohd Fauzi; SAMADI, Masoud. **Application of a non-linear controller based on recurrent neural network for coordinated of PSS and ASMES.** In: 2015 15th International Conference on Control, Automation and Systems (ICCAS). IEEE, 2015. p. 153-157.

SUNDARESWARAN, K.; RAZIA BEGUM, S. **Genetic tuning of a power system stabilizer.** European transactions on electrical power, v. 14, n. 3, p. 151-160, 2004.

TANG, Yufei et al. **Power system stability control for a wind farm based on adaptive dynamic programming.** IEEE Transactions on Smart Grid, v. 6, n. 1, p. 166-177, 2014.

TRONCI, S.; BARATTI, R.. **A Gain-Scheduling PI Control Based on Neural Networks.** Complexity, v. 2017, 2017.

VILELA. L. B.; MATEUS. T. H. A. **Aplicação de rede neural NARX para a previsão do preço de soja.** Paraíba, 2016.

VITTAL, Eknath; O'MALLEY, Mark; KEANE, Andrew. **Rotor angle stability with high penetrations of wind generation.** IEEE Transactions on Power Systems, v. 27, n. 1, p. 353-362, 2011.

VON ZUBEN, EA932-Prof. **Tópicos avançados: controle robusto, controle adaptativo e controle inteligente.** 2003.

WANG, D. et al. **Parameters tuning of power system stabilizer PSS4B using hybrid particle swarm optimization algorithm.** International Transactions on Electrical Energy Systems, v. 28, n. 9, p. e2598, 2018.

Xie R, Kamwa I, Rimorov D, Moeini A. **Fundamental study of common mode small-signal frequency oscillations in power systems.** Int J Electr Power Energy Syst. 2019;106:201-209, ISSN 0142-0615. <https://doi.org/10.1016/j.ijepes.2018.09.042>.

XIE, R. et al. **Fundamental study of common mode small-signal frequency oscillations in power systems**. International Journal of Electrical Power & Energy Systems, v. 106, p. 201-209, 2019.

YOUSEFIAN, R.; KAMALASADAN, S.. **A review of neural network based machine learning approaches for rotor angle stability control**. arXiv preprint arXiv:1701.01214, 2017.

ZACHARIA, L.; ASPROU, M.; KYRIAKIDES, E.. **Wide Area Control of Governors and Power System Stabilizers With an Adaptive Tuning of Coordination Signals**. IEEE Open Access Journal of Power and Energy, v. 7, p. 70-81, 2019.



## APÊNDICE A – ALGORITMOS GENÉTICOS

Os Algoritmos Genéticos (AGs) foram inspirados pela teoria Darwiniana de seleção natural e de reprodução genética. Charles Darwin afirmou que a sobrevivência de um organismo é afetada pela seguinte regra: "é a espécie mais forte que sobrevive". Dessa forma, sua teoria assegura que a mutação e a evolução estejam presentes em todas as espécies, uma vez que a sobrevivência dos indivíduos está diretamente ligada à capacidade de adaptação em diferentes ambientes (AMARAL, 2008).

O conceito de seleção natural serviu de base para o entendimento da evolução e com ele, então, foi desenvolvido um algoritmo matemático que auxilia em problemas que envolvam otimização. Tal mecanismo modifica repetidamente uma determinada população com a finalidade de buscar a melhor combinação possível, isto é, a que tende a "evoluir" em direção à solução ótima, atendendo os requisitos estipulados. Portanto, os AGs são métodos de busca estocástica, que imitam a metáfora da evolução biológica (AMARAL, 2008).

A Tabela 7 apresenta a relação entre o processo de evolução e um problema a ser resolvido computacionalmente.

Tabela 7 – Relação entre o processo de evolução natural e um problema computacional

<b>Evolução Natural</b>	<b>Problema Computacional</b>
Indivíduo	Solução de um problema
População	Conjunto de soluções
Cromossomo	Representação de uma solução
Gene	Parte da representação de uma solução
Cruzamento, Mutação	Operadores de Busca
Seleção Natural	Reutilizar as melhores aproximações

Fonte: (AMARAL, 2008)

O AG consiste no desenvolvimento de um algoritmo com os seguintes passos, (TELES, 2010) e (AMARAL, 2008):

- **Definição da População:** é o ponto de partida para a evolução do AG e é gerada aleatoriamente. Cada indivíduo da população corresponde a uma solução do problema.
- **Forma de Avaliação:** é realizada pelo meio de uma função que melhor represente o problema e tem por objetivo fornecer uma medida de aptidão de cada indivíduo. Representa a adaptabilidade do indivíduo em seu habitat e a sua capacidade de sobrevivência, ou seja, avalia se o indivíduo está apto para se tornar uma solução ótima.

A evolução pode se dar pelos seguintes processos:

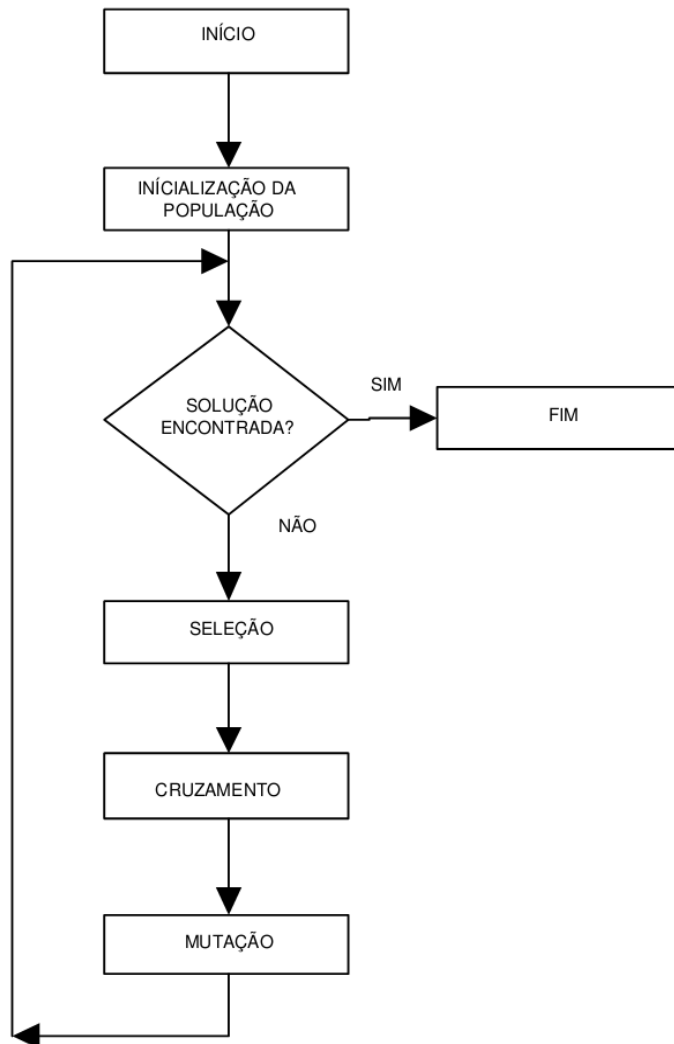
- **Seleção:** a ideia básica do processo de seleção é permitir que os indivíduos com maior aptidão, tenham maiores chances de reprodução. Tal escolha pode ser realizada de inúmeras maneiras, como, por exemplo, a Seleção por Método da Roleta e a Seleção por Torneio.
- **Cruzamento:** é o operador responsável pela propagação das características dos indivíduos mais aptos da população por meio da troca do material genético. Existem vários tipos de cruzamentos, dentre eles, o cruzamento simples e o cruzamento heurístico.
- **Mutação:** a operação de mutação possibilita uma maior varredura do espaço de estados e auxilia a minimizar o problema de mínimos locais. A mutação modifica o valor de um gene de um indivíduo sorteado aleatoriamente com uma determinada probabilidade, denominada de probabilidade de mutação. A probabilidade de mutação é fornecida pelo projetista e representa a probabilidade com que cada cromossomo sofre mutação. Uma baixa probabilidade de mutação previne que uma dada posição fique estagnada em um valor. Numa alta probabilidade de mutação, a busca se torna essencialmente aleatória.

A evolução final é estabelecida como sendo uma:

- **Nova população:** após os processos de seleção, cruzamento e mutação, uma nova população é gerada e o processo recomeça até o problema atingir o critério de parada que é a solução desejada.

Os passos supracitados são ordenados diante de uma estrutura básica que pode ser visualizada na Figura 58.

Figura 58 – Estrutura Básica de um AG



Fonte: adaptada de Amaral 2008

## APÊNDICE B – REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são representações matemáticas inspiradas em observações feitas em processos do cérebro humano com o intuito de reproduzir a aprendizagem e fazer generalizações do processo dele (PRIDDY; KELLER, 2005). Em termos computacionais elas são uma família de algoritmos estatísticos de aprendizagem utilizados para aproximar funções as quais podem depender de uma grande quantidade de entradas. A RNA é uma tentativa de reproduzir a aprendizagem e generalizações de processo do cérebro humano (COURY; JORGE, 1997).

As RNAs são comumente concebidas como um sistema de neurônios interconectados que computam os valores das entradas e são capazes de aprendizado e reconhecimento de padrões graças a sua natureza adaptativa (COURY; JORGE, 1997).

O controle de sistemas não-lineares é um assunto que desperta amplo interesse dos pesquisadores. A grande maioria dos controladores usam técnicas clássicas de controle baseadas na linearização de sistemas físicos com ganhos programados. A utilização de RNA's para controle de sistemas não-lineares mostra-se muito mais eficiente em relação aos modelos tradicionais, diminuindo consideravelmente o erro em regime e tornando a resposta transitória mais suave (MAMANI, 2004).

Um neurônio corresponde a uma célula que está relacionada a vários outros neurônios, formando uma rede. Através dessa rede, cada neurônio é capaz de receber sinais, processá-los, chegar a uma conclusão, gerar e transmitir um sinal elétrico para outro neurônio. No cérebro humano, estima-se uma quantidade de cem bilhões de neurônios (FIORI, 2007). A estrutura do neurônio é dividida em:

Corpo celular: responsável em realizar as atividades químicas, alimentando o neurônio;


- Dendritos: são terminais prolongados responsáveis em receber sinais de outros neurônios;
- Axônios: fibra nervosa que possui alta resistência elétrica e capacitância, possui a função de transmitir os sinais elétricos gerado por determinado neurônio.

Figura 59 mostra a divisão estrutural de um neurônio humano.

A estrutura do neurônio é dividida em:

- Corpo celular: responsável em realizar as atividades químicas, alimentando o neurônio;
- Dendritos: são terminais prolongados responsáveis em receber sinais de outros neurônios;
- Axônios: fibra nervosa que possui alta resistência elétrica e capacitância, possui a função de transmitir os sinais elétricos gerado por determinado neurônio.

Figura 59 – Estrutura de um neurônio humano.



Fonte: (FIORI, 2007).

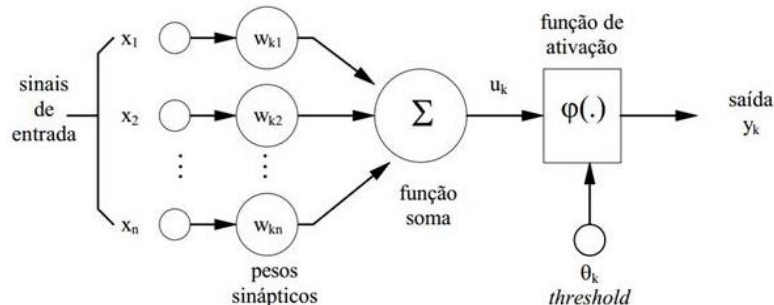
Para que exista a geração e a transmissão de um sinal por determinado neurônio é necessário que a captação de todos os sinais, através dos dendritos, seja maior que um certo limiar. Nessa condição, os axônios liberam substâncias químicas chamadas de neurotransmissores através de sinais elétricos ocorrendo assim a transmissão de sinal, conhecida como sinapse (FIORI, 2007).

Estima-se que no cérebro humano existam cerca de  $10^{15}$  (um milhão de bilhões) de conexões entre os neurônios. Os 100.000 genes existentes no corpo humano não são suficientes para estabelecer todas as conexões entre os neurônios e, para resolver isso, o cérebro cria muitas conexões, conforme cada neurônio procura seu destino predeterminado geneticamente. Conforme o cérebro vai se desenvolvendo e aprendendo, ele elimina as conexões desnecessárias, mantendo as que são úteis (CAMPOS, 2004).

Figura 60 apresenta o modelo de neurônio concebido por (HAYKIN, 2009).



Figura 60 – Modelo não-linear de um neurônio



Fonte: (HAYKIN, 2009)

Quando existente, um sinal na entrada escalar  $x_m$  é multiplicado pelo peso escalar  $w_{km}$  formando o produto  $w_{km}x_m$  que é enviado para o somador. Na outra entrada, tem-se o valor 1 que é multiplicada pelo fator  $b$  (bias) sendo também enviado ao somador. O resultado  $v_k$  do somador é enviado para a função de ativação  $\varphi(\cdot)$  que, por sua vez, produzirá o sinal escalar de saída  $y_k$  do neurônio.


Existem diversos modelos de função de ativação que têm como objetivo representar as não linearidades de um sistema e restringir a amplitude do sinal de saída de um controlador. Dependendo do tipo da função de ativação que é utilizada, o estado de ativação poderá ser discreto ou contínuo. Para o caso discreto, utilizam-se funções de ativação binárias como a função degrau. No caso contínuo, utilizam-se funções de ativação não lineares, não decrescente e que assumem valores em um intervalo do eixo dos números reais (HAYKIN, 2009).

Este tipo de função é a mais utilizada na construção de redes neurais. Seu gráfico em forma de “S” apresenta um equilíbrio entre um comportamento linear e um não linear. A equação (14) representa a função logística que é um exemplo de função sigmoide:

$$q(v) = \frac{1}{1 + \exp(-av)} \quad (13)$$

onde, “ $a$ ” determina a inclinação da curva e “ $v$ ” é a ativação. A Figura 61 apresenta o gráfico da função de ativação:

Figura 61 – Gráfico da função de ativação sigmoide



Fonte: (MAMANI, 2004).

A função logística geralmente é usada em redes de múltiplas camadas que utilizam o algoritmo *backpropagation* para retropropagar o erro (MAMANI, 2004).

A maneira como os neurônios estão organizados está diretamente relacionada à forma como a rede neural realizará o treinamento, ou seja, o tipo de algoritmo a ser utilizado. Basicamente, pode-se distinguir três tipos de arquiteturas de rede:

- *Perceptron*: alimentada com camada única sem realimentação (*feedforward*):
- *Perceptron* Múltiplas Camadas: alimentada com várias camadas sem realimentação (*feedforward*):
- Recorrentes: possui retropropagação do erro.

O processo de aprendizagem das RNAs é muito importante porque ele é complexo e determinará diretamente a resposta a ser atingida. A etapa de treinamento da rede tem a finalidade de determinar os pesos sinápticos dos neurônios e os níveis de bias para uma determinada aplicação. Os valores dos

pesos são obtidos através de repetidas apresentações de um conjunto de dados para a rede. Cada ciclo completo de apresentação desses dados é denominado época. Esse processo segue repetidamente até atingir um critério de parada pré-estabelecido. Os dados, geralmente, são divididos em 80% para treino e 20% para testes (HAYKIN, 2009).

A rede neural tende a ter uma boa generalização, mesmo com os dados de entrada sendo um pouco diferentes dos apresentados no treinamento. Se apresentado um volume excessivo de dados nesse processo, a rede pode memorizar esses dados gerando resultados equivocados. Essa perda da capacidade de generalização é chamada de *overfitting* (HAYKIN, 2009).

O processo de aproximação se torna mais eficiente utilizando duas camadas ocultas, pois, utilizando somente uma, os neurônios tendem a interagir entre si globalmente. As características locais são selecionadas na primeira camada, onde parte desses neurônios separam o espaço de entrada em regiões e os demais aprendem as características locais das regiões. A segunda camada recebe as informações da primeira e atuam em uma região particular do espaço de entrada aprendendo as características globais dessa região e fornecendo um sinal nulo de saída para as demais regiões (HAYKIN, 2009).

## APÊNDICE C – Script NARX Matlab

```

% entradas - input time series.
% saída - feedback time series.

X = tonndata(entrada,false,false);
T = tonndata(saida,false,false);

% Escolhendo a função de treinamento
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

% Criando a rede neural Non-linear Autoregressive Network with External Input
- NARX
inputDelays = 1:6;
feedbackDelays = 1:6;
hiddenLayerSize = 3;
hiddenLayerSize2 = 3;
net = narxnet(inputDelays,feedbackDelays,[hiddenLayerSize,hiddenLayerSize2],
'open',trainFcn);

% Escolhendo entradas e feedback
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};

% Preparando as entradas para treinamento e simulação
[x,xi,ai,t] = preparets(net,X,{},T);

net.divideFcn = 'divideint'; % Divide os dados randomicamente
net.divideMode = 'time'; % Divide a cada ciclo
net.divideParam.trainRatio = 90/100;
net.divideParam.valRatio = 5/100;
net.divideParam.testRatio = 5/100;

% Escolhendo a função para performance.
net.performFcn = 'mse'; % Mean Squared Error

% Plot
net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
'plotregression','plotresponse','ploterrcorr','plotinerrcorr'};

% Treinando a rede neural
[net,tr] = train(net,x,t,xi,ai);

% Teste
y = net(x,xi,ai);
e = gsubtract(t,y);
performance = perform(net,t,y)

```

```

trainTargets = gmultiply(t,tr.trainMask);
valTargets = gmultiply(t,tr.valMask);
testTargets = gmultiply(t,tr.testMask);
trainPerformance = perform(net,trainTargets,y)
valPerformance = perform(net,valTargets,y)
testPerformance = perform(net,testTargets,y)

```

#### % Visualização da rede neural

```
view(net)
```

#### % Closed Loop Network

```

netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] = preparets(netc,X,{},T);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(net,tc,yc)

```

#### % Multi-step Prediction

```

numTimesteps = size(x,2);
knownOutputTimesteps = 1:(numTimesteps-5);
predictOutputTimesteps = (numTimesteps-4):numTimesteps;
X1 = X(:,knownOutputTimesteps);
T1 = T(:,knownOutputTimesteps);
[x1,xio,aio] = preparets(net,X1,{},T1);
[y1,xfo,afo] = net(x1,xio,aio);

```

#### % Estados finais

```

x2 = X(1,predictOutputTimesteps);
[netc,xic,aic] = closeloop(net,xfo,afo);
[y2,xfc,afc] = netc(x2,xic,aic);
multiStepPerformance = perform(net,T(1,predictOutputTimesteps),y2)

```

#### % Step-Ahead Prediction Network

```

nets = removedelay(net);
nets.name = [net.name ' - Predict One Step Ahead'];
view(nets)
[xs,xis,ais,ts] = preparets(nets,X,{},T);
ys = nets(xs,xis,ais);
stepAheadPerformance = perform(nets,ts,ys)

```

#### % Gera a função da neural

```

genFunction(net,'myNeuralNetworkFunction');
y = myNeuralNetworkFunction(x,xi,ai);

```

#### % Gera a neural em matrizes apenas

```

genFunction(net,'myNeuralNetworkFunction','MatrixOnly','yes');
x1 = cell2mat(x(1,:));
x2 = cell2mat(x(2,:));
xi1 = cell2mat(xi(1,:));

```

```
xi2 = cell2mat(xi(2,:));  
y = myNeuralNetworkFunction(x1,x2,xi1,xi2);  
% Gera a neural para o simulink  
gensim(net);
```

**APÊNDICE D – Função custo global para o AG**

```
function CUSTO_GLOBAL = AG_PSS4B(x);
%ENTRADA DOS VALORES DE MINIMIZACAO

fl=x(1);
kl=x(2);
fi=x(3);
ki=x(4);
fh=x(5);
kh=x(6);

xn=[x(1) x(2) x(3) x(4) x(5) x(6)];

assignin('base','xn',xn) ;
assignin('base','fl',fl) ;
assignin('base','kl',kl) ;
assignin('base','fi',fi) ;
assignin('base','ki',ki) ;
assignin('base','fh',fh) ;
assignin('base','kh',kh) ;

%PROGRAMA DE CÁLCULO DOS INDICES DE DESEMPENHO
opts = simset('DstWorkspace','base', 'SrcWorkspace', 'base'); %DEFINE OP-
COES SIMULACAO
sim('power_PSS_4b',10,opts); % EXECUTA O MODELO SIMULINK

dw=max(evalin('base','dw'));

CUSTO_GLOBAL = dw; %OK
end
```

## APÊNDICE E – Algoritmo de otimização de baleias


O *Whale Optimization Algorithm* (WOA) é aqui proposto como forma de comparação com a metodologia GA-NARX-PSS apresentada na seção anterior. A otimização via WOA foi escolhida para comparação devido a ela ser recentemente utilizada para otimização dos parâmetros do PSS (SAHU, et al., 2019; BUTTI, et al., 2020).

As baleias são consideradas os maiores mamíferos do mundo, sendo que uma baleia adulta pode atingir 30 m de comprimento e pesar 180 toneladas. As baleias são consideradas principalmente como predadores. Elas nunca dormem porque precisam respirar na superfície dos oceanos. O interessante das baleias é que elas são consideradas animais altamente inteligentes e com emoção (HOF; GUCHT, 2007). A Figura 62 mostra este mamífero.

De acordo com Hof e Van Der Gucht (2007), as baleias têm células comuns em certas áreas de seus cérebros semelhantes às dos humanos, chamadas células fusiformes. Essas células são responsáveis pelo julgamento, emoções e comportamentos sociais nos seres humanos. Em outras palavras, as células espinhosas nos diferenciam de outras criaturas. As baleias têm o dobro dessas células do que um ser humano adulto, que é a principal causa de sua esperteza. Está provado que a baleia pode pensar, aprender, julgar, comunicar e tornar-se até emocional como o homem, mas obviamente com um nível muito mais baixo de inteligência. Observou-se que as baleias (principalmente baleias assassinas) também são capazes de desenvolver seu próprio dialeto.



Figura 62 – Método de caça das baleias



Fonte: (MIRJALILI; LEWIS, 2016).

A coisa mais interessante sobre as baleias é o seu método utilizado para a caça. Esse comportamento de forrageamento é chamado de método de alimentação com rede de bolhas (GOLDBOGEN et al., 2013). As baleias da espécie jubarte preferem caçar cardumes ou peixes pequenos próximos à superfície. Observou-se que esse forrageamento é feito criando bolhas distintas ao longo de um círculo ou caminho em forma de espiral, como mostrado na Figura 63. Antes de 2011, esse comportamento era investigado apenas com base na observação da superfície.

Goldbogen et al. (2013) investigaram o comportamento das baleias utilizando sensores de etiqueta. Eles capturaram 300 eventos de alimentação com rede de bolhas derivados de etiquetas de 9 baleias jubarte individuais. Eles encontraram duas manobras associadas à bolha e as chamaram de 'espirais para cima' e 'loops duplos'. Na manobra anterior, as baleias jubarte mergulham cerca de 12 m abaixo e começam a criar bolhas em forma de espiral em torno da presa e logo após nadam em direção à superfície.

A manobra de alimentação de rede de bolhas em espiral é modelada matematicamente para realizar a otimização em (MIRJALILI; LEWIS, 2016). As baleias jubarte podem reconhecer a localização das presas e cercá-las. Como a


posição do design ideal no espaço de pesquisa não é conhecida a priori, o algoritmo WOA pressupõe que a melhor solução atual seja a presa alvo ou esteja próxima da ideal. Após a definição do melhor agente de pesquisa, os outros agentes de pesquisa tentarão atualizar suas posições em relação ao melhor agente de pesquisa. Esse comportamento é representado pelas equações (14) e (15):

$$\vec{D} = [\vec{C} \cdot \vec{X}^* (t) - \vec{X} (t)] \quad (14)$$

$$\vec{X} (t + 1) = \vec{X}^* (t) - \vec{A} \cdot \vec{D} \quad (15)$$

onde  $t$  indica a iteração atual,  $\vec{A}$  e  $\vec{C}$  são vetores de coeficiente,  $\vec{X}^*$  é o vetor de posição da melhor solução obtida até agora,  $\vec{X}$  é o vetor de posição.

Figura 63 – Rede de bolhas em forma de espiral



Fonte: (MIRJALILI; LEWIS, 2016).

Vale ressaltar aqui que  $\vec{X}^*$  das equações (11) e (12) deve ser atualizado em cada iteração, se houver uma solução melhor. Maiores detalhes sobre o algoritmo de otimização podem ser encontrados em (MIRJALILI; LEWIS, 2016).