

VENILTON RODRIGUES DE OLIVEIRA

**AVALIAÇÃO DE DESEMPENHO DE GERADORES ELÉTRICOS VIA REDES
NEURAIAS ARTIFICIAIS**

Dissertação apresentada ao Curso de Pós-Graduação em Computação da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre. Área de concentração: Aplicações (Computação em Potência).

Orientadores: Prof. Julio Cesar Stacchini de Souza, D.Sc.

Prof. Marcus Theodor Schilling, D.Sc.

NITEROI, RJ – BRASIL

JULHO 2009

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

Ficha Catalográfica elaborada pela Biblioteca da Escola de Engenharia e Instituto de Computação da UFF

O48 Oliveira, Venilton Rodrigues de Oliveira.
Avaliação de desempenho de geradores elétricos via redes neurais artificiais /
Venilton Rodrigues de Oliveira. – Niterói, RJ : [s.n.], 2009.
109f.
Orientadores: Julio César Stacchini de Souza.

Dissertação (Mestrado em Computação) - Universidade Federal Fluminense,
2009.

1. Rede neural artificial. 2. Geradores Elétricos. 3. Sistemas de energia
elétrica – redes neurais. 4. Processamento de Sinais. 5. Avaliação de
desempenho. I. Título.

CDD 006.3

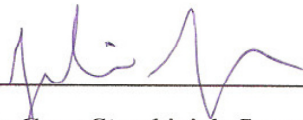
VENILTON RODRIGUES DE OLIVEIRA

**AVALIAÇÃO DE DESEMPENHO DE GERADORES ELÉTRICOS VIA REDES
NEURAIAS ARTIFICIAIS**

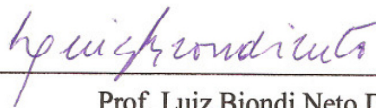
Dissertação apresentada ao Curso de Pós-Graduação em Computação da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre. Área de concentração: Aplicações (Computação em Potência).

Aprovada em 01 de Julho de 2009.

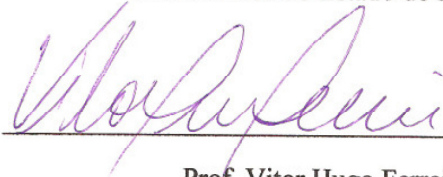
BANCA EXAMINADORA



Prof. Julio Cesar Stacchini de Souza D.Sc. – Orientador
Universidade Federal Fluminense



Prof. Luiz Biondi Neto D.Sc.
Universidade do Estado do Rio de Janeiro



Prof. Vitor Hugo Ferreira D.Sc.
Universidade Federal Fluminense

Este trabalho é dedicado a vocês, meus pais Valdemiro e Lucilia (em memória), aos meus filhos Pedro Henrique e João Vitor e à minha companheira, amiga e mulher Sônia.

Agradecimentos

Em primeiro lugar, a Deus, pelas oportunidades concedidas.

Aos meus pais pela educação, apoio e carinho durante todas as fases da minha vida, que possibilitaram formação da minha determinação.

À UFF – Universidade Federal Fluminense e a UTE TermoCeará, por terem proporcionado todas as condições para a realização deste trabalho.

Aos meus orientadores e amigos, Professores Marcus Theodor Schilling e Julio Cesar Stacchini de Souza, pela orientação, incentivo e tempo a mim dedicados na realização desta Dissertação.

Ao Dr. Jorge Luiz de Araújo Jardim (Nexant, EUA) pela disponibilização da ferramenta computacional utilizada nas simulações e pelas informações a respeito do programa, que possibilitaram a realização deste trabalho.

Ao Eng. Marcelos Groetaers dos Santos (ONS) pelo apoio e amizade e ao Eng. Carlos Alberto da Silva Neto (ONS) pela colaboração e ajuda durante a realização deste trabalho.

Aos meus amigos e familiares, pelo apoio e incentivo durante toda a realização do curso.

A todos aqueles que contribuíram de algum modo para elaboração deste trabalho.

Nota: Este trabalho foi parcialmente apoiado pelo CNPq.

LICENCIAMENTO

O programa ORGANON é de propriedade privada, pertencendo todos os direitos de uso ao Dr. Jorge Luiz de Araújo Jardim (Nexant, EUA). O Operador Nacional do Sistema Elétrico (ONS) possui direitos irrestritos de utilização no ambiente interno da empresa e os direitos de distribuição de licenças de uso, restrito ao território brasileiro, somente para os agentes devidamente habilitados. A utilização do programa ORGANON para o desenvolvimento desta Dissertação foi feita com anuência do Dr. Jardim, tendo sido fornecida versão acadêmica do referido aplicativo.

* * *

Resumo da Dissertação apresentada ao Instituto de Computação da Universidade Federal Fluminense – UFF como parte dos requisitos necessários para a obtenção do Grau de Mestre em Ciências (M. Sc.).

AVALIAÇÃO DE DESEMPENHO DE GERADORES ELÉTRICOS VIA REDES
NEURAIAS ARTIFICIAIS

Venilton Rodrigues de Oliveira

Julho/2009

Orientadores: Prof. Julio Cesar Stacchini de Souza, D.Sc.

Prof. Marcus Theodor Schilling, D.Sc.

Esta Dissertação apresenta uma metodologia para a avaliação do desempenho dinâmico de geradores elétricos. Técnicas de processamento de sinais, como a análise de Prony e a transformada rápida de Fourier são empregadas para descrever padrões de comportamento dinâmico do gerador e seus controladores. Um simulador computacional construído no programa ORGANON foi empregado para obter os padrões de desempenho, que são posteriormente utilizados para o aprendizado das redes neurais. Estas redes são treinadas para classificar o desempenho do regulador de tensão, do regulador de velocidade e do sinal adicional estabilizador (PSS) como normais ou anormais. Testes são realizados utilizando dados de um gerador do sistema elétrico brasileiro e os resultados são apresentados e discutidos.

Summary of the Dissertation presented to the Institute of Computation of the Fluminense Federal University – UFF to fulfill the necessary requirements to obtain the Degree of Master in Sciences (M.Sc.).

ELECTRICAL GENERATORS PERFORMANCE EVALUATION
USING NEURAL NETWORKS

Venilton Rodrigues de Oliveira

July/2009

Advisors: Prof. Julio Cesar Stacchini de Souza, D.Sc.

Prof. Marcus Theodor Schilling, D.Sc.

This work presents a methodology for the evaluation of synchronous generation dynamic performance of electrical generators. Signal Processing Techniques, such as the Prony analysis and the Fast Fourier Transform are employed to describe patterns that represent the dynamic performance of the generators. A computational tool has been constructed to extract those patterns, which will constitute the training sets of artificial neural networks. The neural networks are designed to classify the performance of generators voltage and speed control systems either as normal or abnormal. Test results for a typical thermoelectric generator are presented.

Sumário

Lista de Figuras.....	xii
Lista de Tabelas	xiv
Capítulo I Introdução	15
I.1 Considerações Preliminares	15
I.2 Conceitos Básicos	16
I.3 Métodos Para a Detecção de Falhas	18
I.4 Objetivo da Dissertação	22
I.5 Publicação Desta Dissertação.....	22
I.6 Estrutura da Dissertação.....	22
Capítulo II Métodos de Processamento de Sinais	24
II.1 Introdução.....	24
II.2 Método de Prony	25
II.3 Implementação do Algoritmo de Prony	28
II.4 Implementação do Espectro de Frequência por Fourier	29
II.5 Exemplo Ilustrativo.....	32
II.6 Conclusões	38
Capítulo III Redes Neurais Artificiais	39

III.1	Introdução.....	39
III.2	Redes Neurais Artificiais	40
III.3	Breve Histórico Sobre Redes Neurais	42
III.4	Características Gerais.....	45
III.5	Processos de Aprendizado.....	50
III.5.1	Aprendizado Supervisionado	51
III.5.2	Aprendizado Não-Supervisionado	52
III.6	Rede Perceptron de Múltiplas Camadas	53
III.7	Aspectos Computacionais	59
III.8	Conclusões	62
Capítulo IV	Metodologia Proposta	63
IV.1	Introdução.....	63
IV.2	Ambiente de Simulação	64
IV.3	Construção das Bases de Treinamento	68
IV.4	Seleção do Modelo Neural	75
IV.5	Obtenção das Classificações	77
IV.6	Avaliação de Desempenho das Redes Neurais.....	78
IV.7	Conclusões	80
Capítulo V	Testes e Resultados.....	81
V.1	Introdução.....	81
V.2	Descrição do Gerador Utilizado para Teste	82

V.3	Simulação das Situações de Operação.....	84
V.4	Treinamento dos Classificadores Neurais.....	88
V.5	Obtenção de Classificações.....	90
V.6	Resultados	90
V.7	Conclusões	97
Capítulo VI	Conclusões.....	98
VI.1	Retrospectiva	98
VI.2	Principais Conclusões	99
VI.3	Perspectiva	100
	Referências Bibliográficas.....	102
	Apêndice A: Escolha das Arquiteturas das Redes Neurais.....	106

Lista de Figuras

Figura II-1	Filtro do pré-processo	29
Figura II-2	Tensão terminal	34
Figura II-3	Decomposição espectral de Prony para a tensão terminal	34
Figura II-4	Decomposição espectral de Fourier para a tensão terminal	35
Figura II-5	Potência elétrica	35
Figura II-6	Decomposição espectral de Prony para a potência elétrica	36
Figura II-7	Decomposição espectral de Fourier para a potência elétrica	36
Figura II-8	Corrente elétrica	37
Figura II-9	Decomposição espectral de Prony para a corrente elétrica	37
Figura II-10	Decomposição espectral de Fourier para a corrente elétrica	38
Figura III-1	Constituintes da célula neuronal	41
Figura III-2	Esquema da unidade McCulloch e Pitts	46
Figura III-3	Organização em camadas	47
Figura III-4	(a) Rede não-realimentada (b) Rede realimentada	48
Figura III-5	Funções degrau de ativação	49
Figura III-6	Função combinação linear de ativação	49
Figura III-7	Função sigmóide de ativação	50
Figura III-8	Aprendizado supervisionado	52
Figura III-9	Rede de perceptron de múltiplas camadas	54
Figura IV-1	Sistema teste do ambiente de simulação.	65
Figura IV-2	Interface de simulação	66

Figura IV-3	Diagrama de blocos do regulador de tensão	70
Figura IV-4	Diagrama de blocos do regulador de velocidade	70
Figura IV-5	Diagrama de blocos do sinal adicional estabilizador	71
Figura V-1	Concepção de um sistema integrado de diagnóstico	96
Figura A-1	Percentual de acertos da tensão terminal para o RT	106
Figura A-2	Percentual de acertos da corrente da armadura para o RT	107
Figura A-3	Percentual de acertos da potência ativa para o RT	107
Figura A-4	Percentual de acertos da tensão terminal para o RV	107
Figura A-5	Percentual de acertos da corrente da armadura para o RV	108
Figura A-6	Percentual de acertos da potência ativa para o RV	108
Figura A-7	Percentual de acertos da tensão terminal para o PSS	109
Figura A-8	Percentual de acertos da corrente da armadura para o PSS	109
Figura A-9	Percentual de acertos da potência ativa para o PSS	109

* * *

Lista de Tabelas

Tabela II-1	Ponto de operação da primeira avaliação	33
Tabela IV-1	Índices gerados pelo ambiente de simulação.	67
Tabela IV-2	Variáveis de entrada – Pré-processamento via método de Prony	72
Tabela IV-3	Variáveis de entrada – Pré-processamento via método de Fourier	73
Tabela IV-4	Bases de dados para treinamento	74
Tabela V-1	Dados do gerador térmico	83
Tabela V-2	Dados do regulador de tensão do gerador térmico	83
Tabela V-3	Dados do regulador de velocidade do gerador térmico	84
Tabela V-4	Dados do PSS do gerador térmico	84
Tabela V-5	Simulações para obtenção da base de treinamento para o RT	86
Tabela V-6	Simulações para obtenção da base de treinamento para o RV	87
Tabela V-7	Simulações para o treinamento da RNA do PSS	88
Tabela V-8	Classificadores de desempenho da RNA para os reguladores	89
Tabela V-9	Resultados para o conjunto de treinamento para o RT	91
Tabela V-10	Resultados para o conjunto de testes para o RT	91
Tabela V-11	Resultados para o conjunto de treinamento para o RV	92
Tabela V-12	Resultados para o conjunto de testes para o RV	92
Tabela V-13	Resultados para o conjunto de treinamento para o PSS	93
Tabela V-14	Resultados para o conjunto de testes para o PSS	93

* * *

Capítulo I

Introdução

I.1 Considerações Preliminares

Todo aparato físico, utilizado em processos de produção industrial, está sujeito a uma variação natural de desempenho, que pode ocorrer tanto no sentido da melhoria como no sentido da degradação. O chamado fenômeno do rejuvenescimento, sob o ponto de vista de desempenho estatístico, embora raro, ocorre quando se verifica uma tendência de diminuição do número de falhas dos aparatos ao longo do tempo. Já o denominado envelhecimento, mais usual, caracteriza-se pelo aumento do número de defeitos, proporcionalmente ao tempo de uso dos equipamentos. Tanto o rejuvenescimento quanto o envelhecimento podem ocorrer em diferentes fases da vida útil dos equipamentos.

No que concerne aos grandes tópicos mais recorrentes na literatura que investiga a ocorrência de falhas em geradores, identificam-se as variantes seguintes [1]:

- (i) Estudos dos mecanismos gerais de falha dos geradores, [2] e [3];
- (ii) Estudos específicos das causas de falhas em rotores e estatores;
- (iii) Metodologias para investigar o uso de geradores sob condições de estresse;
- (iv) Metodologias de monitoração de desempenho (procedimentos, técnicas de medição, etc.), [4] a [9];
- (v) Estudos estatísticos (coleta de dados, avaliação de custos, balanço de benefícios, etc.).

O escopo desta dissertação abrange apenas o item (iv), relacionado ao fenômeno do envelhecimento estatístico, caracterizado pela ocorrência de defeitos, falhas ou situações operacionais indesejáveis, cada vez mais frequentes em geradores elétricos e derivados da degradação natural decorrente do uso e da passagem do tempo.

Nessa perspectiva, a possibilidade de identificação precoce de falhas revela-se como um subsídio relevante para o aperfeiçoamento dos processos de manutenção preventiva dos equipamentos e eventual alteração das estratégias operacionais, que possibilita corrigir os defeitos de forma programada.

I.2 Conceitos Básicos

No âmbito desta dissertação, entende-se como *defeito incipiente* aquele caracterizado pelo aparecimento de indícios marginais ou padrões operativos do gerador, que embora aparentemente inócuos, são anormais ou indesejáveis, porém ainda permitem que o equipamento permaneça em operação. Tais defeitos prenunciam a possível ocorrência iminente de um defeito de grandes proporções e conseqüências.

Define-se *disponibilidade absoluta* como o percentual do tempo total de observação, durante o qual o equipamento está disponível. Define-se *disponibilidade relativa* como o percentual de tempo de operação programada, durante o qual o equipamento está disponível. Para o processo produtivo, interessa que esses dois indicadores, atinjam os maiores valores possíveis.

Entretanto, dado que as paradas programadas dos equipamentos são inevitáveis, as mesmas apresentam-se como ideais para o combate aos denominados defeitos incipientes. Tal prática contribui para o aumento da confiabilidade, diminuição de intervenções de manutenção e concomitante redução de custos operacionais, pois se aproveita o tempo de parada programada para solucionar tais defeitos.

Consoante a literatura do tema, pode-se afirmar que a operação em presença dos chamados defeitos incipientes afeta significativamente o desempenho das máquinas, já

fornecendo, portanto, um sinal ou subsídio para o desenvolvimento de estratégias para prevenção, antes da ocorrência do defeito de maior gravidade, que poderão provocar um longo tempo de parada do gerador, diminuindo assim a disponibilidade do mesmo.

Portanto, a identificação precoce de falhas maiores pela via da contínua monitoração e detecção de defeitos incipientes, contribui para o aumento da confiabilidade operacional e redução de custos globais.

Admite-se que as principais causas da ocorrência de defeitos em geradores advêm dos seguintes fatores:

- **Localção em ambiente hostil** (e.g. altos níveis de corrosão, poluição, temperatura, maresia, intempéries, invasões, sabotagem, etc.);
- **Má prática operativa** (e.g. violação das especificações operacionais do equipamento, estratégia de manutenção inadequada, submissão a regimes transitórios além da capacidade de projeto, operadores despreparados ou desmotivados, etc.);
- **Fabricação e/ou montagem** (e.g. problemas de origem estrutural, componentes da baixa qualidade, equipamento de segunda mão, etc.).

As duas primeiras causas podem gerar os já citados defeitos incipientes, enquanto a última causa gera os denominados *defeitos genéticos*, dado sua natureza já intrínseca ao próprio equipamento (i.e. erro de projeto, montagem defeituosa, uso de equipamento já sucateado, etc.). Os defeitos de natureza genética são de difícil tratamento e usualmente são detectados logo no início da operação efetiva do equipamento.

Quanto à *tipologia da localização dos defeitos usuais*, os mesmos podem ser enquadrados, a grosso modo, em duas classes, quais sejam:

- **Defeitos externos:** tais como queda de fase, desbalanço de torque, sobrecarga mecânica, travamento de rotor, atritos espúrios, etc.;

- **Defeitos internos:** tais como curto-circuito nos terminais internos, curto-circuito nos enrolamentos, curtos a terra, desgaste de mancais, quebras de barras do rotor, furos na caldeira, vazamentos em válvulas de pressão, acúmulo de resíduos, etc.

Tantos os defeitos de natureza interna quanto os de natureza externa podem dar origem aos defeitos incipientes, embora ocorram situações na quais a evidência do problema manifesta-se de forma abrupta, sem chances de detecção antecipada pela presença de defeito incipiente.

A detecção de defeitos incipientes relacionados a defeitos internos, apresenta-se como a situação ideal para o uso de técnicas preventivas automatizadas, que auxiliam a inibição de uma deterioração posterior, de maior gravidade.

Por outro lado, o surgimento de defeitos incipientes associados a defeitos externos também incentiva a tomadas de ações corretivas precoces, muito embora a característica de externalidade aparentemente indique um tratamento mais fácil do problema.

I.3 Métodos Para a Detecção de Falhas

De acordo com a literatura, constata-se que podem ser claramente reconhecidas duas famílias de métodos para a detecção precoce de falhas em geradores, a saber:

- **Métodos invasivos:** São aqueles que implicam na desintegração (desmontagem) temporária do equipamento, exigindo portanto a total parada do mesmo por períodos de tempo compatíveis com a dificuldade da operação;
- **Métodos não invasivos:** São aqueles baseados em medições, preferencialmente de baixo custo e fácil realização, e que não demandam

a desmontagem das máquinas. Por prescindir da parada total dos equipamentos, estes são os métodos ideais para a monitoração em tempo real dos defeitos incipientes.

Esta dissertação tem como foco principal a avaliação de geradores elétricos utilizando métodos não invasivos. A implementação prática destes métodos compreende, em geral as seguintes etapas:

- (i) Identificação das variáveis a serem monitoradas, vis-à-vis o tipo de defeito incipiente que se deseja tratar;
- (ii) Composição do esquema de detecção, envolvendo a aquisição de sinais, estratégia lógica, algoritmos computacionais e sistema de tomada de decisão;
- (iii) Sintonia interativa de procedimentos, critérios e padrões;
- (iv) Validação e comissionamento.

A literatura registra a existência de diversos métodos de natureza não invasiva, os quais podem ser classificados em duas categorias:

(A) Métodos baseados na experiência do operador: São os que dependem da diagnose direta de um operador experiente, prescindindo do conhecimento de modelos matemáticos de qualquer espécie. O processo depende tão-somente da observação sensorial (audição, visão, olfato e tato, registrando-se até mesmo, em raros casos, a acuidade gustativa do operador - há registros de identificação de corrosão ferrosa em dutos de água, via provas do paladar da água). As desvantagens dessa estratégia advêm da dificuldade de

treinamento do operador, possibilidades de acidentes, danos à saúde, diagnoses nem sempre precisas e custos envolvidos;

(B) **Métodos baseados em formulações matemáticas:** São técnicas que exigem a aquisição de dados operacionais da máquina, via equipamentos especiais. A análise desses dados pode ser realizada em tempo real ou fora de operação, resultando na diagnose de desempenho do equipamento. Existem diversas técnicas, entre as quais cabe citar as seguintes:

- **Métodos de rádio-frequência:** São esquemas que injetam sinais de rádio-frequência nos enrolamentos do estator, visando à medição das distorções presentes na forma da onda. Com base nessa análise, determina-se se há defeitos no isolamento do enrolamento. A técnica é cara e justifica-se apenas para grandes máquinas.
- **Métodos de análise de partículas:** Baseia-se na análise laboratorial de amostras de substâncias extraídas da máquina, tais como óleo, resíduos, raspas, etc. Tais métodos são de aplicação restrita para um conjunto particular de problemas.
- **Métodos de vibração:** Baseiam-se na análise dos modos oscilatórios de vibração mecânica do equipamento. São métodos sofisticados e que demandam um conhecimento prévio dos padrões vibratórios (*e.g.* espectros de frequência) associados à normalidade. A análise de vibrações se subdivide, basicamente em três grandes grupos:
 - *Técnicas no domínio do tempo (sinais analógicos ou digitais);*
 - *Técnicas no domínio da frequência (ou ordem);*
 - *Técnicas estatísticas.*

- **Métodos de assinatura térmica:** São métodos que dependem do reconhecimento de padrões térmicos de diferentes perfis operativos, tanto normais, quanto defeituosos. Também são técnicas muito sofisticadas e de cara implementação.
- **Métodos de ultrasonografia:** Dependem do mapeamento do tráfego de ondas sonoras no corpo do equipamento. Viabilizam a detecção de rachaduras e podem demandar a parada da máquina.
- **Métodos óticos:** Úteis em processos de alinhamentos mecânicos, utilizando feixe ótico a laser.
- **Métodos de estimação de parâmetros:** São os métodos mais comuns, embora requeiram um apurado modelo matemático do gerador e um grande entendimento da dinâmica do aparato. Os parâmetros escolhidos usualmente refletem as condições do gerador. Por exemplo, sabe-se que a condição dos enrolamentos dos mancais afeta o coeficiente de amortecimento relacionado ao torque mecânico do gerador. Assim, quando os enrolamentos se desgastam, o coeficiente de amortecimento aumenta. Desta forma, medindo-se a velocidade do rotor, pode-se estimar o valor do coeficiente de amortecimento, e por conseguinte inferir sobre as condições dos enrolamentos. Uma das dificuldades dessa estratégia reside na interpretação dos resultados, que têm intrinsecamente uma natureza difusa.
- **Métodos automáticos baseados em inteligência computacional:** São os métodos mais avançados, atualmente disponíveis, e que lançam mão de técnicas computacionais de fronteira tais como as baseadas em modelagem matemática rigorosa da dinâmica do gerador, redes neurais artificiais, sistemas especialistas, reconhecimento de padrões, sistemas de inferência difusa, mineração de dados, técnicas estatísticas e todo um arsenal de métodos de tomada de decisão, [1], [10] e [11]. Permitem a

diagnose em tempo real do gerador, porém exigem um esquema sofisticado de medições.

I.4 Objetivo da Dissertação

O objetivo desta Dissertação é *apresentar um novo procedimento para a identificação de defeitos incipientes em controladores de geradores elétricos através de uma Rede Neural Artificial (RNA). A RNA será responsável pelo reconhecimento de padrões representados através do espectro de frequência utilizando análise de Prony e Fourier.*

I.5 Publicação Desta Dissertação

Ao longo do desenvolvimento desta dissertação foi publicado um artigo no XVII Congresso Brasileiro de Automática realizado em Juiz de Fora, Minas Gerais com o título *Avaliação em Tempo Real de Desempenho Dinâmico de Geradores Elétricos via Redes Neurais Artificiais* [12]

I.6 Estrutura da Dissertação

Organizacionalmente, o Capítulo II desta Dissertação apresenta os métodos de processamento de sinais utilizado, sendo eles, o método de Prony e Fourier, os resultados comparativos entre os métodos e um exemplo ilustrativo da implementação dos métodos no programa ORGANON.

O Capítulo III apresenta um breve histórico sobre redes neurais artificiais (RNA), as características gerais de uma RNA, aspectos computacionais de aprendizagem e um descritivo sobre a rede Perceptron de múltiplas camadas.

O Capítulo IV descreve a metodologia adotada e a sistemática para obter os dados para o treinamento da RNA. Além disso, apresenta também a estrutura da rede neural utilizada

O Capítulo V apresenta os testes realizados, os resultados das simulações, e a avaliação do desempenho da rede neural.

Por fim, o Capítulo VI apresenta as conclusões deste trabalho e as perspectivas futuras de desenvolvimento.

* * *

Capítulo II

Métodos de Processamento de Sinais

II.1 Introdução

O diagnóstico de defeitos em equipamentos ainda é um tópico de pesquisa relevante na área de reconhecimento de padrões e testes assistidos por computadores. O método de simulação pré-teste, reconhecido como o método de dicionário de padrões, é uma das técnicas importantes de diagnóstico. O equipamento em teste é simulado sob diversas condições normais e de defeito (ou anormais) e os resultados são armazenados em forma de tabelas. O conceito de reconhecimento de padrões é então aplicado para a identificação das condições de defeito.

O método de dicionário para identificação de defeitos inclui quatro módulos básicos: o simulador ou módulo de aquisição, o pré-processador, o módulo de extração de características e o classificador.

O módulo de pré-processamento compacta os dados de simulação ou aquisição em características adequadas ao propósito de classificação. Transformadas de Fourier e Prony [13] podem ser utilizadas como pré-processadores. A Transformada de Fourier converte uma forma de onda em componentes de frequência. O método de Prony decompõe o sinal em componentes modais fornecendo a frequência, o módulo e o amortecimento das componentes dominantes, que resultam em representações acuradas das formas de onda simuladas.

Nem todas as características levantadas pelo pré-processador terão a mesma importância para o propósito de classificação. Um algoritmo de extração ou seleção de

características é essencial para reduzir o custo e aumentar a eficiência da classificação. Enquanto os algoritmos de seleção de características escolhem um subconjunto destas, algoritmos de extração de características criam novas características baseado em transformações ou combinações das características de entrada. Conseqüentemente, um conjunto adequado de características é selecionado ou calculado e então armazenados em um dicionário ou tabela de consulta.

Neste capítulo discute-se os métodos de análise de Prony e Fourier e apresenta-se um exemplo ilustrativo utilizado no reconhecimento e identificação do padrão de comportamento do gerador.

II.2 Método de Prony

O método de Prony [13] tem a função de decompor uma resposta no tempo de um sinal em suas componentes modais, [14], [15] e [16], ou seja, dado um sinal $y(t)$, a análise de Prony o decompõe em uma soma ponderada de n exponenciais conforme a equação (II-1). Isto permite a extração das características importantes do sinal.

$$y(t) = \sum_{i=1}^n R_i e^{\alpha_i t} \quad (\text{II-1})$$

Ou, na forma discreta:

$$y(k) = \sum_{i=1}^n R_i z_i^k, \quad z_i = e^{\alpha_i \tau} \quad t = k\tau \quad (\text{II-2})$$

Onde $y(t)$ é a aproximação de $\tilde{y}(t)$ e τ é o período de amostragem. Assim, pelo menos ($N \geq 2n$) amostras igualmente espaçadas são necessárias.

O método é baseado na suposição de que o sinal $y(k)$ pode ser escrito como uma combinação linear dos n valores passados. Desta forma, tem-se:

$$y(k) = a_1 y(k-1) + a_2 y(k-2) + \dots + a_n y(k-n) \quad (\text{II-3})$$

Seja o conjunto de vetores de amostras $\{\bar{y}_i\}, i = 1, \dots, n+1$, onde

$$\bar{y}_i = [y(i), y(i+1), \dots, y(i+N-n-1)]^T \quad (\text{II-4})$$

Aplicando (II-3) repetidamente, obtém-se o seguinte sistema de equações lineares:

$$Y\bar{a} = [\bar{y}_n, \bar{y}_{n-1}, \dots, \bar{y}_1] \bar{a} = \bar{y}_{n+1} \quad (\text{II-5})$$

Onde, $\bar{a} = [a_1, a_2, \dots, a_n]^T$

A matriz Y pode ser resolvida em $O(n^2)$ operações se $2n$ amostragens de dados forem usadas. Substituindo-se (II-3) com $k = n$ em (II-2), verifica-se que os modos $\{z_i\}$ são as raízes do polinômio característico:

$$C(z) = z^n - a_1 z^{n-1} \dots - a_n = 0 \quad (\text{II-6})$$

Então, $\alpha_i = \ln(z_i)/\tau$. De (II-2), os resíduos $\{R_i\}$ podem ser calculados a partir do sistema de equações lineares:

$$Z\bar{R} = \bar{y}_1 \quad (\text{II-7})$$

Onde

$$Z = \begin{bmatrix} 1 & 1 & \dots & 1 \\ z_1 & z_2 & \dots & z_n \\ \vdots & \vdots & & \vdots \\ z_1^{N-1} & z_2^{N-1} & \dots & z_n^{N-1} \end{bmatrix} \quad (\text{II-8})$$

$$R = [R_1, R_2, \dots, R_n]^T \quad (\text{II-9})$$

A solução de (II-7) pode ser realizada em $O(n^2)$ operações para o caso quadrado [17]. Nota-se que os expoentes $\{\alpha_i\}$ e os resíduos $\{R_i\}$ podem ser pares complexos conjugados quando $\tilde{y}(t)$ é real.

A principal vantagem do método de Prony está em sua habilidade de estimar um sinal a partir de um conjunto limitado de amostragens. Assim, precisa-se de uma simulação mais curta quando comparado com a necessária para o uso do método de

Fourier. A função de transferência no domínio da frequência pode ser então obtida diretamente da resposta no tempo sem a necessidade da Transformada de Fourier.

O método de Prony tem encontrado muitas aplicações na área de estimação de frequência [18], [19]. Tem sido utilizado em várias aplicações práticas de síntese de padrão de antenas [20], análise e síntese de radiação [21], e trajetória de estados em sistemas de potência [22], entre outras.

II.3 Implementação do Algoritmo de Prony

Para a implantação do método de Prony, foram utilizados os algoritmos do programa ORGANON, [23], [24] e [25], desenvolvidos especialmente para esta pesquisa. A implementação foi realizada conforme os seguintes passos:

1. Pré-processar o sinal amostrado a fim de:
 - a. Tornar o mais estacionaria possível a série temporal;
 - b. Escolher a janela utilizada;
 - c. Filtrar digitalmente altas e baixas frequências fora da faixa de passagem desejada.
2. Estimar a ordem do sistema.
3. Identificar o espectro de frequência.
4. Verificar se o erro é inferior a tolerância. Caso, não seja, aumenta-se a ordem do sistema por um incremento pré-estabelecido e retorna-se ao passo 3.
5. No caso em que o erro seja menor que a tolerância, seleciona-se os modos característicos da resposta do gerador como sendo os de maior amplitude e dentro da banda de passagem desejada (0,2 a 2 Hz).

O filtro utilizado no pré-processamento (passo 1) foi um passa banda com a seguinte estrutura.




Figura II-1 Filtro do pré-processo

II.4 Implementação do Espectro de Frequência por Fourier

A transformada discreta de Fourier possibilita extrair as componentes (espectro) de frequência contidas em um sinal no domínio do tempo, possibilitando identificar as características do sistema em análise.

A Transformada de Fourier [17] baseia-se na premissa de que um processo físico pode ser descrito tanto no domínio do tempo através de valores de alguma grandeza h função do tempo, por exemplo, $h(t)$, quanto no domínio da frequência, onde o processo é especificado pela amplitude H (geralmente um número complexo indicando também a fase) em função da frequência f , ou seja, $H(f)$, com $-\infty < f < \infty$. Por várias razões, é conveniente pensar em $h(t)$ e $H(f)$ como sendo duas representações da mesma função. Estas representações estão relacionadas pelas equações da transformada de Fourier.

$$H(f) = \int_{-\infty}^{\infty} h(t)e^{2\pi jft} dt \quad (\text{II-10})$$

$$h(t) = \int_{-\infty}^{\infty} H(f) e^{-2\pi jft} df \quad (\text{II-11})$$

Se t é medido em segundos, então f na equação (II-10) e (II-11) é medida em ciclos por segundo, ou Hertz. Em alguns casos é mais conveniente utilizar a frequência angular ω , que é medida em radianos por segundo.

$$\omega \equiv 2\pi f \quad H(\omega) \equiv [H(f)]_{f=\omega/2\pi} \quad (\text{II-12})$$

Então, as equações (II-10) e (II-11) passam a ser

$$H(\omega) = \int_{-\infty}^{\infty} h(t) e^{i\omega t} dt \quad (\text{II-13})$$

$$h(t) = \int_{-\infty}^{\infty} H(\omega) e^{-i\omega t} d\omega \quad (\text{II-14})$$

Já a Transformada Discreta de Fourier, na prática, a função $h(t)$ é amostrada em intervalos de tempo igualmente espaçados. Seja T o intervalo de tempo entre duas amostragens consecutivas, de tal forma que a seqüência de valores amostrados seja:

$$h_n = h(nT) \quad \dots \quad n = \dots, -3, -2, -1, 0, 1, 2, 3, \dots \quad (\text{II-15})$$

O recíproco do intervalo de tempo T é denominado taxa de amostragem, se T é medido em segundos, por exemplo, então a taxa de amostragem é o número de amostras gravadas por segundo.

Para cada intervalo de amostragem T , também existe uma frequência especial f_c , chamada de frequência crítica de Nyquist, dada por:

$$f_c = \frac{1}{2T} \quad (\text{II-16})$$

Se uma onda senoidal com a frequência crítica de Nyquist é amostrada no seu valor de pico positivo, então a próxima amostragem será no valor de pico negativo, a amostra seguinte no pico positivo, e assim por diante. Expresso de outra forma a amostragem crítica de uma onda senoidal é de duas amostras por ciclo.

Dois propriedades importantes da frequência crítica de Nyquist são as seguintes:

1. Se uma função contínua $h(t)$, amostrada em intervalos T , tem a banda de passagem limitada por frequências de magnitude inferior a f_c , ou seja, se $H(f) = 0$ para todo $|f| > f_c$, então a função $h(t)$ é completamente determinada por suas amostras h_n .
2. Se a função contínua $h(t)$, amostrada em intervalos T , não tem a banda de passagem limitada por frequências de magnitude inferior a f_c , acontece que toda a densidade de espectro de frequência que reside fora da faixa $-f_c < f < f_c$ move espuriamente para esta faixa. Este fenômeno é chamado de *aliasing*. Qualquer componente de frequência fora da faixa $(-f_c, f_c)$ é falsamente transladada para dentro desta faixa pelo simples ato de amostragem discreta.

A maneira de reduzir o efeito de *aliasing* é:

- Saber o limite natural da faixa de passagem do sinal, ou forçar um limite conhecido através de filtragem analógica do sinal contínuo, e então;
- Amostrar-lo com uma taxa suficientemente rápida para prover dois pontos por ciclo da frequência mais alta presente na forma de onda.

O objetivo então é estimar a transformada discreta de Fourier de uma função a partir de um número finito de pontos de amostragem.

II.5 Exemplo Ilustrativo

Neste trabalho a análise de Prony e a transformada de Fourier foram definidas como pré-processamento dos sinais elétricos obtidos do gerador, o módulo de pré-processamento compacta os dados de simulação das transformadas de Fourier e Prony e resultam em representações acuradas das formas de onda obtidas. Neste exemplo ilustrativo, foram realizadas simulações com um sistema teste, que será apresentado em detalhes no item IV.2 desta dissertação, para avaliar o emprego dos métodos de pré-processamento no programa de simulação, programa este que também será descrito em detalhes no item IV.2 desta dissertação.

Na simulação realizada para avaliação a implementação dos métodos, foi aplicado um degrau de 0,02 pu na referência do regulador de tensão, sendo monitoradas três grandezas elétricas (tensão terminal, corrente elétrica e potência elétrica do gerador) para avaliar as características do espectro de frequência em Prony e Fourier.

Utilizou-se como sistema teste um gerador ligado a uma barra infinita através de uma impedância externa, de valor igual à reatância transitória de eixo direto do próprio gerador. Para esta simulação foi mantida a tensão terminal igual a 1,0 pu, com potência ativa em 50% da potência nominal e com a reatância de 0,245 pu, que corresponde à reatância transitória de eixo direto do gerador. O ponto de operação do gerador esta definido na Tabela II-1.

Tabela II-1 Ponto de operação da primeira avaliação

Grandeza	Valor (pu)
Tensão Terminal	1,00
Potência Ativa	0,50
Potência Reativa	0,104
Reatância Externa	0,245

Na avaliação utilizando a tensão terminal, Figura II-2, observa-se que o espectro de frequência pelo método de Prony fornece as componentes modais da resposta no tempo, ou seja, a amplitude, o amortecimento e a frequência, a Figura II-3 apresenta a frequência e a amplitude dos modos calculados. Já o espectro frequência pelo método de Fourier, Figura II-4, fornece a frequência e a amplitude do modo dominante. O amortecimento não foi incluído na figura da decomposição de Prony para comparar as mesmas grandezas obtidas da decomposição de Fourier.

Para o sinal da potência ativa, verifica-se na resposta no tempo que esta grandeza possui uma frequência de oscilação característica com o valor de 1,88Hz, Figura II-5. O método de Prony, Figura II-6, fornece informações com valores distintos da frequências característica. Já o método de Fourier identifica exatamente a frequência de 1,88Hz, Figura II-7. Ressalta-se que o método de Prony fornece o também o amortecimento que não foi incluído na Figura II-6.

A corrente da armadura do gerador, Figura II-8, é composta pela corrente reativa e pela corrente ativa do gerador, tendo portanto, uma semelhança com a tensão terminal na sua mudança de valor (parte reativa) e uma semelhança com a potência elétrica na sua oscilação (parte ativa). Com relação ao espectro de Prony, Figura II-9, verifica-se que este espectro obtém mais valores de frequência que o espectro de Fourier, Figura II-10. No espectro de Fourier predomina a influência da componente de corrente contínua, ou seja, com frequência zero, o que corresponde à mudança de valor, que por sua vez é muito semelhante à análise da tensão terminal.




Figura II-2 Tensão terminal

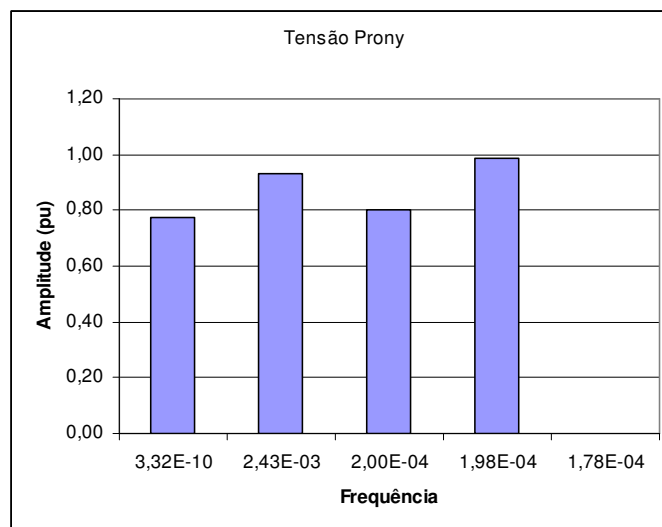


Figura II-3 Decomposição espectral de Prony para a tensão terminal

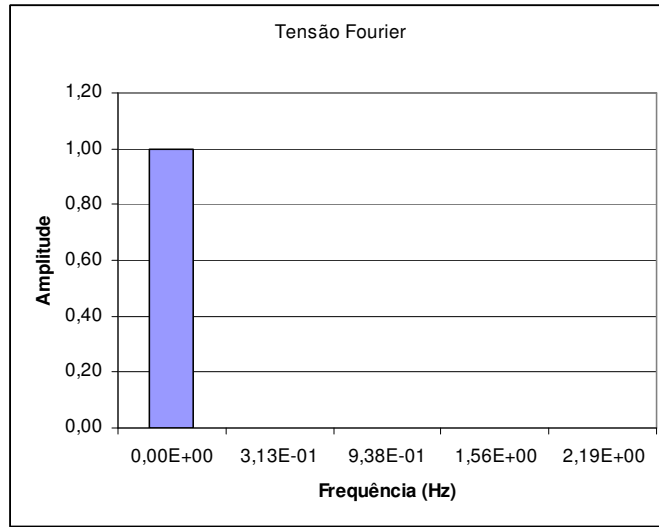


Figura II-4 Decomposição espectral de Fourier para a tensão terminal




Figura II-5 Potência elétrica

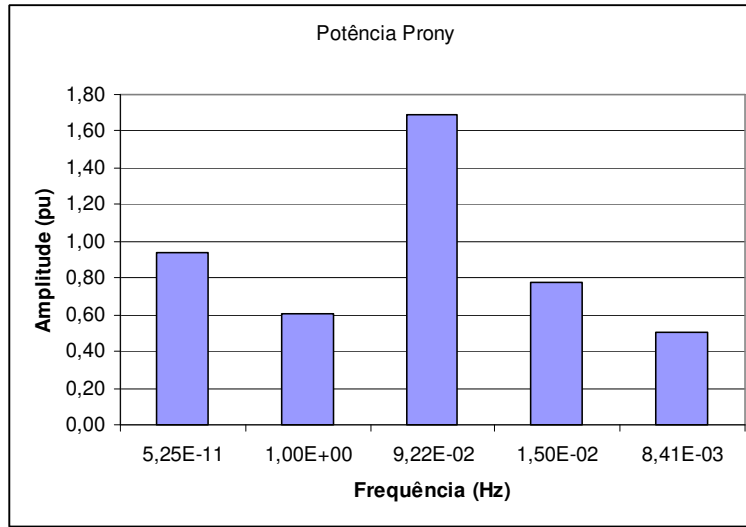


Figura II-6 Decomposição espectral de Prony para a potência elétrica




Figura II-7 Decomposição espectral de Fourier para a potência elétrica




Figura II-8 Corrente elétrica




Figura II-9 Decomposição espectral de Prony para a corrente elétrica

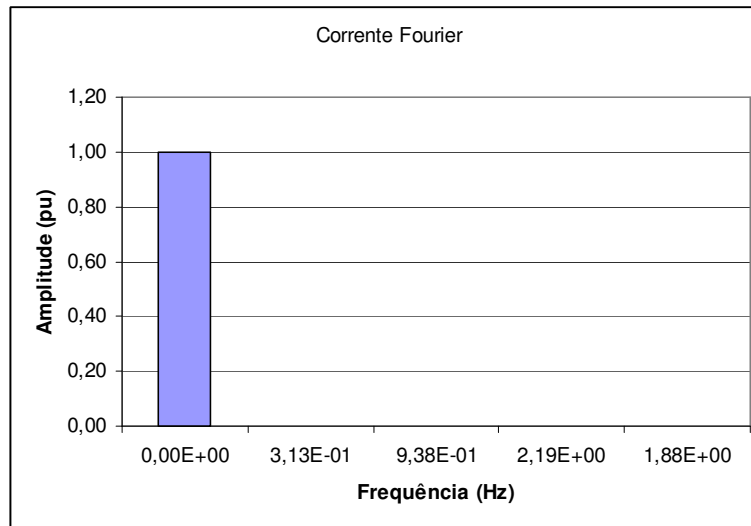


Figura II-10 Decomposição espectral de Fourier para a corrente elétrica

II.6 Conclusões

Neste capítulo foram descritos os métodos de Prony e Fourier implementados no programa ORGANON para realizar o pré-processamento dos sinais de tensão, corrente e potência do gerador elétrico. Foi realizada uma simulação ilustrativa de degrau na referência do regulador de tensão para verificar a implantação de cada método no programa ORGANON, e a sua verificação com a resposta no tempo de cada grandeza disponibilizada pelo programa.

No próximo capítulo será realizado um descritivo sobre redes neurais artificiais utilizadas para o reconhecimento de padrões de condições normais e anormais de operação de um gerador elétrico, para ser utilizado com identificador das condições do gerador.

* * *

Capítulo III

Redes Neurais Artificiais

III.1 Introdução

Neste capítulo são apresentados conceitos sobre redes neurais artificiais, bem como, o modelo de rede neural a ser empregado no reconhecimento de padrões para o processo de inferência visando o diagnóstico e detecção de condições operativas normais e anormais em geradores elétricos.

O treinamento de uma rede neural consiste em ajustar os pesos das conexões entre neurônios de acordo com uma regra de aprendizagem pré-estabelecida, podendo ser classificado como supervisionado ou não-supervisionado. A diferença básica entre estes dois tipos de treinamento é que no primeiro a regra de aprendizagem baseia-se na existência de um conjunto de pares ordenados formados pelas entradas e as respectivas saídas, enquanto no último o aprendizado da rede se dá dispondo-se apenas de um conjunto de entradas de interesse.

As regras de aprendizagem estão normalmente associadas aos modelos específicos para os quais foram criadas e não apresentam, em geral, plausibilidade biológica. Deve-se ressaltar que, para um dado modelo de rede neural, nem sempre pode-se conseguir que sua regra de aprendizagem atue de modo a fazê-lo reproduzir um processamento de dados arbitrário. Isto ocorre devido a limitações impostas pela topologia de suas conexões e modelos de seus neurônios.

Após o processo de treinamento a rede neural deverá exibir uma capacidade de interpolação e extrapolação sobre as associações contidas no conjunto de padrões de

treinamento, devendo portanto ser capaz de desempenhar adequadamente a função para a qual foi projetada mesmo quando submetida a padrões inéditos.

A seguir será apresentado um descritivo sobre redes neurais, um breve histórico, assim como um dos modelos mais difundidos de redes neurais, o qual será aplicado neste trabalho.

III.2 Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas de unidades de processamento, já o cérebro de um mamífero pode ter muitos bilhões de neurônios [27].

O sistema nervoso é formado por um conjunto extremamente complexo de células, os neurônios, Figura III-1. Eles têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos *dendritos*, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída.




Figura III-1 Constituintes da célula neuronal

Os neurônios se comunicam através de *sinapses*. *Sinapse* é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre eles. Os impulsos recebidos por um neurônio **A**, em um determinado momento, são processados, e atingindo um dado limiar de ação, o neurônio **A** dispara, produzindo uma substância neurotransmissora que flui do corpo celular para o axônio, que pode estar conectado a um dendrito de outro neurônio **B**. O neurotransmissor pode diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio **B**. Este processo depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor.

Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 10^{11} neurônios, e o número de sinapses é de mais de 10^{14} , configurando uma rede muito complexa. Portanto, o cérebro é um “computador” altamente complexo, não linear e paralelo (sistema de processamento de informação). Ele tem a capacidade de organizar os neurônios, assim como realizar certos cálculos (reconhecimentos de padrões, percepção e controle motor) muitas vezes mais rápido do que o computador digital mais rápido nos dias de hoje, [27].

Em sua forma mais geral, uma rede neural artificial é uma máquina projetada para modelar a maneira pela qual o cérebro desempenha uma determinada tarefa ou função de interesse. Abaixo define-se uma rede neural como uma máquina adaptativa, [28]:

Uma rede neural é um processador paralelo distribuído que tem a propriedade de armazenar conhecimento experimental e disponibilizá-lo para uso. Ela se assemelha ao modo neural biológico em dois aspectos:

- *O conhecimento é adquirido pela rede através de um processo de aprendizagem;*
- *Os pesos das conexões interneurais, conhecidos como pesos sinápticos, são usados para armazenar o conhecimento.*

O processo usado para realizar a aprendizagem é chamado de algoritmo de aprendizagem, tendo como função modificar os pesos sinápticos da rede, a fim de se obter o desempenho desejado para a solução de um dado problema.

Vários modelos de redes neurais têm sido propostos na literatura e aplicados na solução dos mais diversos problemas. Estes modelos diferem basicamente quanto à topologia da rede, modelo adotado para os neurônios e regras utilizadas para a evolução de estado e aprendizagem da rede.

III.3 Breve Histórico Sobre Redes Neurais

O primeiro modelo artificial de um neurônio biológico foi fruto do trabalho pioneiro de 1943 [28], onde é apresentada uma discussão sofisticada de redes lógicas de nós (chamados também nós MCP) e novas idéias sobre máquinas de estados finitos, elementos de decisão de limiar lineares e representações lógicas de várias formas de comportamento e memória. Parte da discussão em RNAs gira em torno dos métodos de aprendizado para que os nós possam ser capazes de executar uma determinada função.

O trabalho de McCulloch e Pitts se concentra muito mais em descrever um modelo artificial de um neurônio e de apresentar as suas capacidades computacionais do que apresentar técnicas de aprendizado.

O aprendizado de redes biológicas e artificiais veio a ser objeto de estudo somente alguns anos depois do trabalho de McCulloch e Pitts. O primeiro trabalho de que se tem ligação direta com aprendizado foi apresentado por Donald Hebb [29], em 1949. Hebb mostrou como a aprendizagem das redes neurais é conseguida através da variação dos pesos de entrada dos nós. Ele propôs uma teoria para explicar o aprendizado em nós biológicos baseada no reforço das ligações sinápticas entre nós excitados. A regra de Hebb, como é conhecida a sua teoria, foi interpretada do ponto de vista matemático, sendo hoje utilizada em vários algoritmos de aprendizado. Mais tarde, Widrow e Hoff [30] sugeriram uma regra de aprendizado, conhecida como regra de Widrow-Hoff ou *regra delta*, que é ainda hoje bastante utilizada. Esta, por sua vez, é baseada no método do gradiente para minimização do erro na saída de um neurônio com resposta linear.

Em 1958, Frank Rosenblatt [31] demonstrou com o seu novo modelo, o *perceptron*, que, se fossem acrescentadas de *sinapses* ajustáveis, as RNAs com nós MCP poderiam ser treinadas para classificar certos tipos de padrões. Rosenblatt [32] descreveu uma topologia de RNA, estruturas de ligação entre os nós e, o mais importante, propôs um algoritmo para treinar a rede para executar determinados tipos de função. O *perceptron* mais simples descrito por Rosenblatt possui três camadas:

- A primeira recebe as entradas do exterior e possui conexões fixas (retina);
- A segunda recebe impulsos da primeira através de conexões cuja eficiência de transmissão (peso) é ajustável e;
- Por sua vez, envia saídas para a terceira camada (resposta).

Este tipo elementar de perceptron comporta-se como um classificador de padrões, dividindo o espaço de entrada em regiões distintas para cada uma das classes existentes. Este tipo de perceptron somente é capaz de classificar classes que sejam linearmente separáveis. Inicialmente, a saída da rede é aleatória, mas pelo ajuste gradual dos pesos o perceptron é treinado para fornecer saídas de acordo com os dados do conjunto de treinamento. O que Rosenblatt buscava - e os "novos conexionistas" continuam buscando - era projetar RNAs que fossem capazes de fazer descobertas interessantes sem a necessidade de regras.

Em 1969, Minsky e Papert [33] chamaram a atenção para algumas tarefas que o *perceptron* não era capaz de executar, já que este só resolve problemas linearmente separáveis. O *perceptron*, por exemplo, não consegue detectar paridade, conectividade e simetria, que são problemas não linearmente separáveis, além do clássico e simples problema do "OU exclusivo" (XOR). Estes são exemplos de "problemas que são difíceis de aprender" (*hard learning problems*). Problemas que são difíceis de aprender formam uma grande classe de funções que não pode ser desprezada. O principal argumento de Minsky e Papert era que o problema do crescimento explosivo, tanto de espaço ocupado, como do tempo requerido para a solução de problemas complexos, afetariam cedo ou tarde, as RNAs, inclusive os *perceptrons*. Argumentaram também que, embora existisse um algoritmo de aprendizado que garantia a convergência para modelos com uma única camada de nós, como era o caso do modelo *perceptron* original, o mesmo não acontecia para redes *perceptrons* com mais de uma camada.

Nos anos 70, a abordagem conexionista ficou adormecida (em grande parte devido à repercussão do trabalho de Minsky e Papert), apesar de alguns poucos pesquisadores continuarem trabalhando na área. Entre eles podem ser citados Igor Aleksander [34] (redes sem pesos) na Inglaterra, Kunihiko Fukushima [35] (cognitron e neocognitron) no Japão, Steven Grossberg [36] (sistemas auto-adaptativos) nos EUA e Teuvo Kohonen (Memórias associativas e auto-organizadas) [37] na Finlândia.

Em 1982, John Hopfield publicou um artigo [38] que chamou a atenção das propriedades associativas das RNAs. O grande feito de Hopfield foi, sem dúvida,

mostrar a relação entre redes recorrentes auto-associativas e sistemas físicos, o que abriu também espaço para a utilização de teorias correntes da Física para estudar tais modelos. A descrição do algoritmo de treinamento *backpropagation* alguns anos mais tarde [39], o qual foi proposto inicialmente por Paul Werbos [40], mostrou que a visão de Minsky e Papert sobre o *perceptron* era bastante pessimista. As RNAs de múltiplas camadas são, sem dúvida, capazes de resolver "problemas que são difíceis de aprender". A partir de meados da década de 80 houve nova explosão de interesse pelas RNAs na comunidade científica. Dois outros fatores foram responsáveis pela retomada de interesse na área:

- Em primeiro lugar, o avanço da tecnologia, sobretudo da microeletrônica, que vem permitindo a realização física de modelo de nós e sua interconexão de modo antes impensável;
- Em segundo, o fato da abordagem via sistemas especialistas, a despeito de seu sucesso em algumas aplicações, não ter conseguido resolver uma grande variedade de problemas.

III.4 Características Gerais

Uma Rede Neural Artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades geralmente são conectadas por canais de comunicação que estão associados a um determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede [27].

A operação de uma unidade de processamento [41] pode ser resumida da seguinte maneira, Figura III-2:

- a) Sinais são apresentados à entrada;
- b) Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- c) É feita a soma ponderada dos sinais, que produz um nível de atividade;
- d) Se este nível de atividade exceder um certo limite (*threshold*) a unidade produz uma determinada resposta de saída.

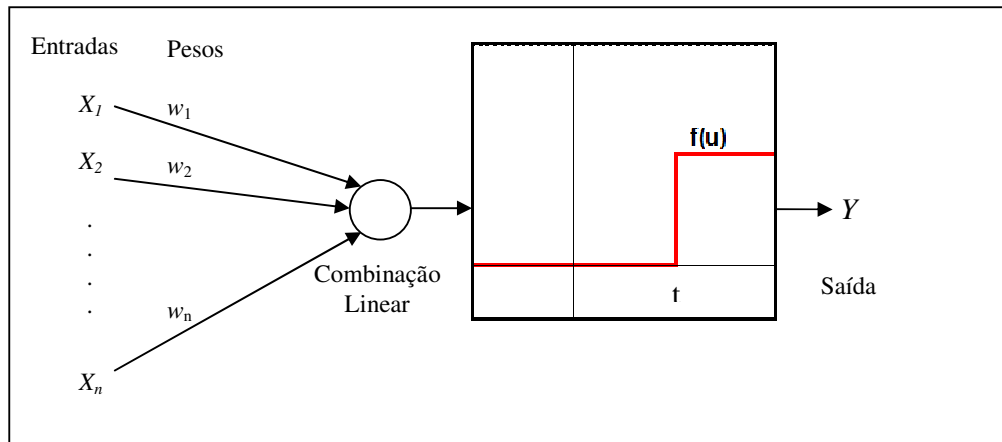


Figura III-2 Esquema da unidade McCulloch e Pitts

Suponha que tenhamos p sinais de entrada X_1, X_2, \dots, X_p e pesos w_1, w_2, \dots, w_p e limitador t , com sinais assumindo valores booleanos (0 ou 1) e pesos assumindo valores reais.

Neste modelo, o nível de atividade u é dado por:

$$u = w_1X_1 + w_2X_2 + \dots + w_pX_p \quad (\text{III-1})$$

A saída $y = f(u)$ é dada por:

$$y = 1, \quad \text{se } u \geq t \quad (\text{III-2})$$

Ou

$$y = 0, \quad \text{se } u < t \quad (\text{III-3})$$

Os modelos de redes neurais artificiais possuem regras de treinamento, onde os pesos das conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas, Figura III-3, com unidades que podem estar conectadas às unidades da camada posterior.

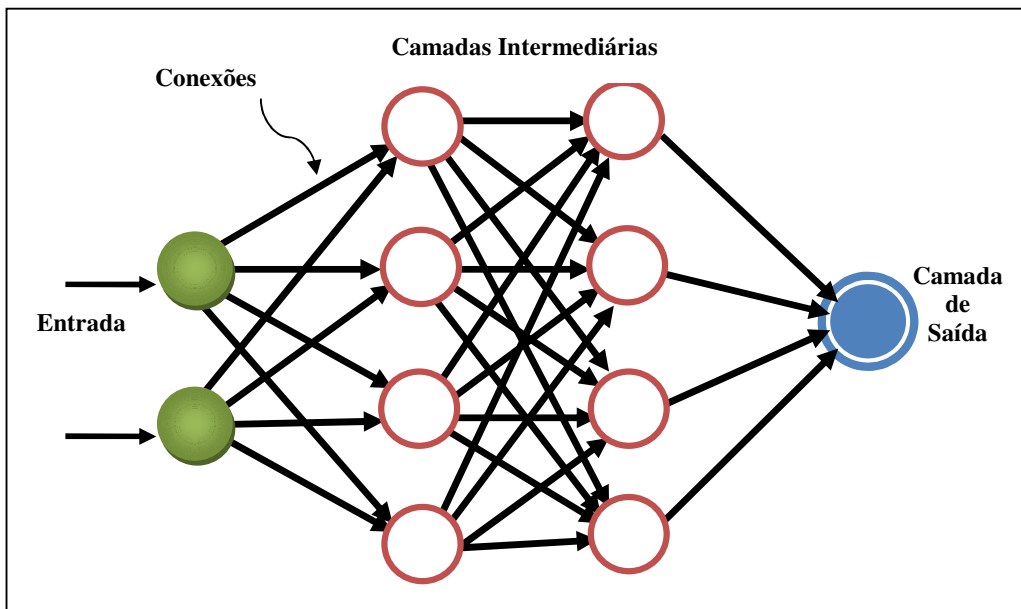


Figura III-3 Organização em camadas

Usualmente as camadas são classificadas em três grupos:

- **Camada de Entrada:** onde os padrões são apresentados à rede, através dos nós de transferência;
- **Camadas Intermediárias ou Escondidas:** onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- **Camada de Saída:** onde o resultado final é concluído e apresentado.

Uma rede neural é especificada principalmente pela sua topologia, pelas características dos nós e pela regra de treinamento.

Quanto à topologia, a rede pode ser realimentada ou não-realimentada. A rede é realimentada quando se pode encontrar um circuito no grafo orientado que a representa, e não-realimentada, caso contrário. A Figura III-4 ilustra dois destes casos.




Figura III-4 (a) Rede não-realimentada (b) Rede realimentada

Quanto às características dos nós ou neurônios, pode-se dizer que elas estão relacionadas principalmente com as respostas geradas por eles, que são calculadas através de uma função de ativação. Existem vários tipos de funções de ativação, como por exemplo: Função degrau, Figura III-5; Combinador linear, Figura III-6; e Sigmóide, Figura III-7.




Figura III-5 Funções degrau de ativação




Figura III-6 Função combinação linear de ativação




Figura III-7 Função sigmóide de ativação

III.5 Processos de Aprendizado

A propriedade mais importante das redes neurais artificiais é a habilidade de aprender do ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicados a seus pesos, denominado treinamento. O aprendizado ocorre quando a rede neural apresenta um desempenho satisfatório na execução da tarefa para a qual foi projetada.

Denomina-se algoritmo de aprendizado um conjunto de procedimentos bem definidos para a aquisição de conhecimento. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de RNAs. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto, os principais paradigmas de aprendizado são [42]:

➤ **Aprendizado Supervisionado:**

Quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;

➤ **Aprendizado Não Supervisionado (auto-organização):**

Quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;

Denomina-se ciclo uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executada de dois modos:

1) Modo Padrão:

A correção dos pesos acontece a cada apresentação à rede de um exemplar do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplar apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.

2) Modo Batch:

Apenas uma correção é feita por ciclo. Todos os exemplares do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro faz-se as correções dos pesos.

III.5.1 Aprendizado Supervisionado

Este tipo de aprendizado é o mais comumente empregado no treinamento das RNAs, sendo chamado aprendizado supervisionado porque a entrada e a saída desejada

para a rede são fornecidas por um agente externo. O objetivo é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos.

A Figura III-8 ilustra o mecanismo de aprendizado supervisionado.

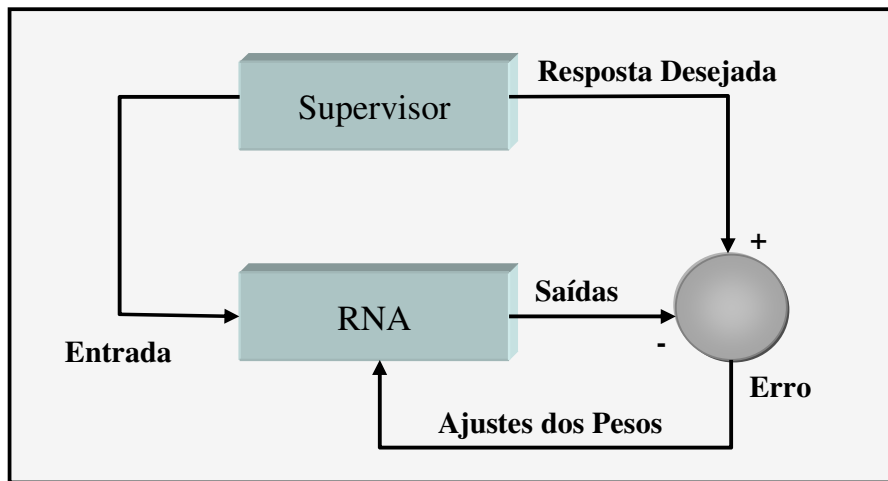


Figura III-8 Aprendizado supervisionado

O supervisor indica explicitamente um comportamento bom ou ruim para a rede, visando direcionar o processo de treinamento. A cada padrão de entrada submetido à rede, compara-se a resposta desejada com a resposta calculada, ajustando-se os pesos das conexões para minimizar o erro de saída. A minimização da diferença é incremental, já que pequenos ajustes são feitos nos pesos a cada etapa do treinamento, de tal forma que estes caminhem para uma solução. A soma dos erros quadráticos de todas as saídas é normalmente utilizada com medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento.

III.5.2 Aprendizado Não-Supervisionado

No aprendizado não-supervisionado, como o próprio nome sugere, não existe um supervisor para acompanhar o processo de aprendizado.

Para estes algoritmos, somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída.

A estrutura do sistema de aprendizado não-supervisionado pode se apresentar sob diferentes formas. Ela pode, por exemplo, consistir de uma camada de entrada, uma camada de saída, conexões *feed-forward* da entrada para a saída e conexões laterais entre os neurônios da camada de saída. Um outro exemplo é uma rede *feed-forward* com múltiplas camadas, onde a livre organização procede na base de camada por camada. Nos dois casos o processo de aprendizado consiste em modificar repetidamente os pesos sinápticos de todas as conexões do sistema em resposta às entradas, [43] e [46].

Redes auto-organizáveis também utilizam aprendizado não supervisionado. RNAs auto-organizáveis possuem um amplo leque de aplicações, principalmente em problema de reconhecimento de padrões e categorização de dados, onde as classes não são conhecidas *a priori*. Dentre os modelos de redes auto-organizáveis mais conhecidas destacam-se os mapas auto-organizáveis de Kohonen [45] e a família de redes ART de Grossberg e Carpenter [46].

III.6 Rede Perceptron de Múltiplas Camadas

Neste modelo de rede os neurônios são dispostos em camadas mutuamente exclusivas, sendo uma camada de entrada, uma ou mais camadas intermediárias, denominadas camadas escondidas, e uma camada de saída, conforme ilustrado na Figura III-9.

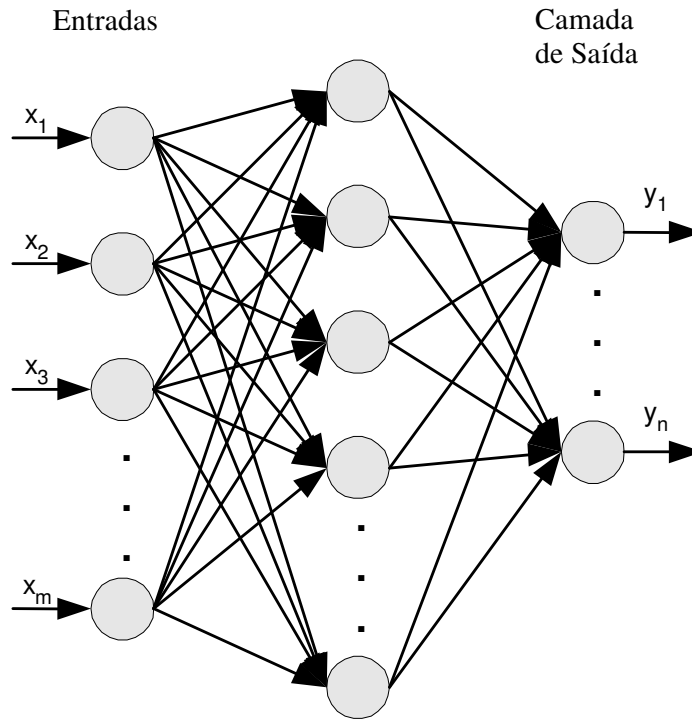


Figura III-9 Rede de perceptron de múltiplas camadas

As conexões entre neurônios da rede são unidirecionais, estando cada neurônio de uma dada camada conectado apenas aos neurônios da camada seguinte. Assim sendo, o padrão de entrada é apresentado na camada de entrada e o sinal recebido é propagado para frente na rede até a camada de saída, que fornece a resposta ao estímulo apresentado.

A rede de perceptrons de múltiplas camadas é comumente referida como modelo da retropropagação de erros devido ao algoritmo de aprendizado a ela aplicado. Neste algoritmo o sinal de entrada é inicialmente propagado para frente nas camadas da rede até que uma determinada saída seja obtida, observando-se que os pesos das conexões entre neurônios são mantidos fixos nesta fase. Como o treinamento é supervisionado, a saída obtida é então confrontada com a saída desejada para o padrão de entrada apresentado e um sinal de erro é produzido. O sinal de erro é então “propagado para trás” pelas camadas da rede e os pesos das conexões entre neurônios são então ajustados

no sentido de tornar a saída obtida mais próxima da saída desejada quando este padrão for novamente apresentado a rede.

O treinamento da rede é obtido através da implementação do método do gradiente decrescente, sendo a rede capaz de aproximar funções contínuas $f: [0,1]^n \rightarrow R^m$ utilizando um conjunto de padrões de treinamento formado por pares entrada-saída da forma $(x_i, f(x_i))$. Para tal, é necessário que o modelo de neurônio adotado possua uma função de ativação não-decrescente, contínua e continuamente diferenciável em R [48]. A função sigmóide é largamente utilizada como função de ativação, pois além de possuir as características acima mencionadas, a sua derivada é facilmente calculada e expressa como função da própria função de ativação, o que é bastante conveniente para efeito de implementação computacional do algoritmo de retropropagação de erros. A função sigmóide é apresentada na equação (III-4) e sua derivada na equação (III-5).

$$g(u) = \frac{1}{1 + e^{-u}} \quad (\text{III-4})$$

$$g'(u) = g(u) (1 - g(u)) \quad (\text{III-5})$$

A função objetivo adotada na implementação do método do gradiente decrescente é a função erro representada na equação (III-6).

$$E = \sum_{k=1}^p E_k \quad (\text{III-6})$$

Onde E_k é o erro obtido na saída da rede quando da apresentação do k -ésimo padrão de um conjunto de treinamento que contém p padrões, sendo dado por:

$$E_k = \frac{1}{2} (t_k - o_k)^2 \quad (\text{III-7})$$

Onde t_k representa o vetor de saída desejado e o_k o vetor de saída obtido.

O algoritmo de retropropagação de erros para treinamento de uma rede de Perceptrons de múltiplas camadas e neurônios com função de ativação do tipo sigmóide consiste dos seguintes passos:

1. Apresentar um padrão de entrada a rede;
2. Propagar o sinal de entrada para frente, calculando os valores de saída dos neurônios de cada camada até atingir a camada de saída, quando então é obtida a saída da rede;
3. Para cada neurônio j da camada de saída, atualizar todos os pesos W_{ij} conforme a equação (III-8).

$$\Delta W_{ij} = \mu \delta_j o_i \quad (\text{III-8})$$

Onde μ é a taxa de aprendizagem, o_i é a saída do neurônio i da camada anterior e δ_j é dada pela expressão (III-9):

$$\delta_j = (t_j - o_j) o_j (1 - o_j) \quad (\text{III-9})$$

Sendo t_j e o_j as saídas desejada e obtida, respectivamente, para o neurônio de saída j .

4. Ajustar os pesos das conexões entre neurônios das camadas escondidas através da equação (III-10).

$$\Delta w_{ki} = \mu \delta'_i o_k \quad (\text{III-10})$$

Onde o_k é a saída do neurônio k de uma camada escondida anterior, que será a entrada do neurônio i e δ'_j é dado pela equação (III-11).

$$\delta'_j = o_j (1 - o_j) \sum w_{ij} \delta_j \quad (\text{III-11})$$

As equações (III-8) e (III-10) são utilizadas para atualizar todos os pesos da rede.

5. Verificar a magnitude do erro após a atualização dos pesos.

É possível ainda alterar o algoritmo acima através da introdução de um termo de momento na equação (III-8) visando melhorar o tempo de convergência. Com isto tem-se que:

$$\Delta w_{ij}(k+1) = \mu \delta_j o_i + \alpha \Delta w_{ij}(k) \quad (\text{III-12})$$

Onde α é a constante de momento que representa o efeito dos ajustes anteriores no ajuste atual. O termo de momento pode prevenir oscilações na busca da solução e evitar mínimos locais da função erro durante o treinamento.

O método da retropropagação do erro apresenta alguns inconvenientes, dentre os quais pode-se destacar:

- Normalmente o tempo para treinamento da rede é muito grande e cresce exponencialmente com o aumento do número de neurônios da rede;
- A escolha de bons parâmetros para o treinamento, tais como constante de aprendizado e de momento, pode ser crucial para a convergência;
- A utilização do método do gradiente descendentes pode fazer com que a convergência se dê para um mínimo local da função de erro.

Conforme foi discutido anteriormente, o sucesso da aplicação de uma rede neural à solução de um dado problema depende, dentre outros fatores, da sensibilidade do projetista na escolha do modelo neural a ser utilizado, o que inclui a arquitetura da rede e o modelo dos neurônios.

Existem dois teoremas importantes relacionados à utilização do modelo da retropropagação de erros para o treinamento da rede Perceptron de Múltiplas Camadas.

O Teorema de Kolmogorov-Hecht-Nielsen [47] garante a existência de uma rede neural não-realimentada, de duas camadas justapostas acima da camada de entrada, capaz de implementar uma função contínua arbitrária. O teorema fixa até mesmo o número de neurônios na camada intermediária: $2m+1$, para m neurônios de entrada. O teorema não especifica entretanto os modelos exatos dos neurônios na rede, garantindo apenas que, com os modelos adequados, pode-se implementar a função de mapeamento.

O Teorema de Cybenko [48] por sua vez não especifica o número de neurônios necessários à camada intermediária, garantindo apenas que esse número é finito. Além disso, ele garante que, utilizando-se por exemplo, função de ativação do tipo sigmóide logística para os neurônios da camada intermediária, é possível obter uma aproximação tão boa quanto se queira de qualquer função contínua. As funções de ativação dos neurônios da camada de saída são simplesmente funções identidade.

Apesar do teorema de Kolmogorov-Hecht-Nielsen parecer mais informativo, o teorema de Cybenko é mais prático pois, no que diz respeito aos modelos dos neurônios, este último é mais construtivo. O teorema de Kolmogorov-Hecht-Nielsen não permite treinar, com a regra da retropropagação de erros a rede cuja existência é garantida. Já o teorema de Cybenko impõe como dificuldade a determinação da arquitetura adequada da rede neural. Apesar disso, garante que é possível buscar tal arquitetura utilizando, durante este processo, o método da retropropagação de erros. Isto evidencia mais uma vez a necessidade de encontrar a arquitetura adequada para a rede neural.

III.7 Aspectos Computacionais

O sucesso em ajustar um modelo neural aos dados que representam um certo problema depende fortemente do projeto da rede neural a ser empregada, o que inclui:

- ✓ Arquitetura da rede;
- ✓ Regra de aprendizagem;
- ✓ Parâmetros de treinamento.

A arquitetura da rede neural a ser empregada nesta dissertação é a Perceptron de Múltiplas Camadas (MLP), bem como a regra de aprendizagem a ser adotada (método da retropropagação de erros) já foram previamente discutidas. A seguir serão discutidos aspectos práticos referentes ao desempenho computacional do modelo escolhido e à escolha dos seus parâmetros de treinamento.

1) Escolha da função de ativação

O processo de treinamento através do método da retropropagação dos erros requer que a função de ativação (modelo) dos neurônios seja continuamente diferenciável. A função sigmóide logística, apresentada na equação (III-4) é largamente utilizada. Esta função, além de ser diferenciável, permite que a maior mudança nos pesos ocorra nos valores intermediários ($g'(u)=0,5$ na equação (III-5)), acelerando o aprendizado quando o neurônio ainda não está comprometido com a resposta 0 ou 1, no caso de saídas binárias.

É importante notar as regiões de saturação na saída de um neurônio que utiliza como modelo a função sigmóide logística, onde os níveis de ativação 1 e 0 nunca podem ser atingidos. Ao se tentar atingi-los, os pesos das conexões crescem exageradamente e o treinamento fica muito lento. Tal região de saturação deve ser evitada.

2) Inicialização dos pesos

Os pesos devem ser inicializados aleatoriamente, idealmente com valores pequenos. É possível que um determinado vetor de pesos iniciais não leve a um bom desempenho da rede MLP durante o treinamento. Isto ocorre quando tal vetor de pesos iniciais faz o processo de treinamento convergir para valores de pesos associados a um mínimo local indesejável da função de energia que

representa o erro global na saída da rede. Nestes casos, a re-inicialização dos pesos da rede é recomendada.

3) Taxa de Aprendizado e Taxa de Momento

A taxa de aprendizado μ , responsável por controlar a magnitude da atualização dos pesos da rede durante o treinamento, geralmente varia na faixa $0 < \mu < 1$. Em situações onde a taxa de decaimento do erro global na saída da rede é muito baixa, é desejável valores mais elevados de μ de forma a acelerar a convergência. Por outro lado, valores elevados de μ (maior atualização dos pesos) podem trazer risco de oscilação no processo de convergência. Caso necessário, um termo de momento pode ser incluído na regra de aprendizagem de forma a representar na atualização dos pesos o efeito de atualizações anteriormente realizadas, reduzindo assim o risco de oscilação.

4) Forma de Apresentação dos Padrões de Treinamento

A apresentação dos padrões de treinamento deve ser realizada em lote, visando melhorar a eficácia do processo de aprendizagem, fazendo com que os pesos da rede sejam atualizados de forma a melhorar o desempenho desta para um conjunto de padrões ao invés de apenas para um único padrão. Tal estratégia faz com que os pesos sejam atualizados em função do erro médio de saída da rede e torna o processo de convergência mais rápido.

5) Validação do Treinamento

O erro global na saída da rede, sobre todo o conjunto de treinamento, é uma medida inicial da capacidade da rede aprender sobre os padrões aos quais

foi exposta. Além desta medida, é necessário também estabelecer índices de desempenho que possam aferir a capacidade apresentada pela rede para resolver o problema que motivou a sua construção. Para tal, é necessário testá-la não apenas com padrões utilizados durante o treinamento, como também padrões inéditos, não apresentados à rede durante a fase de aprendizagem. Os índices de desempenho devem avaliar a capacidade de a rede apresentar boas soluções para o problema. O erro global de treinamento e os indicadores de desempenho podem sugerir a necessidade de promover alterações como, por exemplo, re-inicialização dos pesos da rede, redefinição da arquitetura da rede e/ou parâmetros de treinamento ou até mesmo a inclusão de padrões de treinamento ainda não considerados.

III.8 Conclusões

Neste capítulo foram apresentados aspectos básicos das Redes Neurais Artificiais, bem como, foi apresentado o modelo de RNA a ser utilizado nesta dissertação para realizar diagnósticos sobre a condição operativa de geradores elétricos. As características da rede Perceptron de Múltiplas Camadas (MLP) foram apresentadas, sendo também discutidos os aspectos computacionais relacionados ao seu processo de treinamento e validação.

No Capítulo IV será apresentada a metodologia proposta para identificar condições normais e anormais de operação de geradores elétricos aplicada no desenvolvimento deste trabalho.

* * *

Capítulo IV

Metodologia Proposta

IV.1 Introdução

Neste capítulo será apresentada a metodologia proposta para a construção de classificadores neurais responsáveis por identificar condições normais e anormais de operação de geradores elétricos. Será também descrito o ambiente de simulação empregado para a obtenção das bases de treinamento das redes neurais. Diversas situações de operação foram consideradas, correspondendo a diferentes condições de despacho de geração, de tensão terminal, do acoplamento com o sistema elétrico, etc. Para tais situações foi observado o comportamento da máquina na ausência de defeitos em seus componentes, assim como considerando defeitos no regulador de tensão, no regulador de velocidade e no sinal adicional estabilizador (PSS). Utilizou-se o espectro de Prony e o espectro de Fourier para obter os padrões de frequência para a análise e registro do comportamento da máquina, através da tensão terminal, da potência ativa e da corrente de armadura, frente às diferentes situações de operação.

Será também apresentada a estratégia empregada para a investigação e definição do modelo neural mais adequado ao processo de inferência sobre as condições de operação da máquina em análise. A rede neural a ser empregada é a MLP, cujo modelo estará completamente descrito após a definição de sua arquitetura, modelo dos neurônios e pesos sinápticos (definidos somente após a conclusão da etapa de treinamento). A forma como os parâmetros de treinamento serão explorados para se obter o melhor modelo possível também será apresentada e discutida. Além disso, será definida a forma de avaliação do desempenho dos classificadores neurais construídos

IV.2 Ambiente de Simulação

O programa ORGANON é um *software* de análise de sistema de potência que pode ser usado tanto em estudos de planejamento do sistema elétrico bem como na operação em tempo real. Este programa é uma das ferramentas de análise utilizadas pelo Operador Nacional do Sistema (ONS), [23], [24] e [25], além de manter o seu desenvolvimento. A partir de uma versão modificada do ORGANON foram obtidos os padrões de treinamento, contando com um ambiente de simulação específico para a geração automática de casos que correspondem a diferentes desempenhos do gerador, frente a diversas situações de operação. O ambiente de simulação da versão modificada possibilita carregar os dados da rede elétrica, os parâmetros dinâmicos do gerador, do regulador de tensão (RT), do regulador de velocidade (RV) e do sinal adicional estabilizador (PSS). O evento definido para avaliar o desempenho do gerador é um degrau na referência do regulador de tensão, este evento provoca uma perturbação no sistema e produz uma variação característica no gerador. Para avaliação de desempenho do gerador serão monitoradas três grandezas de forma independente, isto é, uma grandeza por conjunto de simulações. Estas grandezas são a tensão terminal, a potência ativa e a corrente da armadura.

Após o carregamento do sistema elétrico, dos parâmetros dinâmicos do gerador e dos parâmetros dos controladores, o ORGANON monta o sistema teste. Este sistema teste é formado pelo gerador ligado a uma barra infinita através de uma impedância de acoplamento, como mostrado na Figura IV–1. Para cada simulação realizada o valor do ângulo da barra terminal do gerador é mantido em zero grau e os demais parâmetros são ajustados para cada novo ponto de operação do sistema. Por exemplo, o módulo e o ângulo da tensão da barra infinita são calculados em função dos demais parâmetros da rede elétrica. As principais grandezas do sistema teste, tensão terminal (V_t), reatância de acoplamento do sistema (X_e), potência elétrica (P_e) e a potência reativa (Q_e), podem ser mantidas fixas ou variar dentro de uma faixa especificada pelo usuário. A faixa de variação dos parâmetros determina a região possível de operação do gerador, sendo que, os valores dos parâmetros são obtidos de forma aleatória.




Figura IV-1 Sistema teste do ambiente de simulação.

Já os parâmetros dos controladores, isto é, do regulador de tensão, do regulador de velocidade e do sinal adicional estabilizador (PSS), podem variar de forma sequencial ou de forma aleatória, caracterizando assim situações de defeito em tais equipamentos. Adicionalmente, especifica-se o número de simulações desejadas, ou seja, a quantidade de casos a serem simulados. Os resultados das simulações são armazenados em dois arquivos de dados, que compreendem a resposta no tempo da grandeza escolhida para a análise (tensão terminal, potência ativa ou corrente de armadura) e os índices de desempenho calculados (espectro de frequência), correspondendo às saídas do método de Prony e do método de Fourier.

A interface gráfica para a edição das condições de contorno de cada simulação, ilustrada na Figura IV-2, permite selecionar o gerador a ser testado e escolher o formato do arquivo de saída: “Trend” para a resposta no tempo e “Prony” para o espectro de frequência. Além disso, permite escolher a grandeza de saída a ser monitorada e cujo padrão de resposta será utilizado no treinamento da rede neural, “Signal” (V para a tensão terminal, P para potência ativa ou I para corrente da armadura). É possível ainda determinar a quantidade de casos a serem simulados.

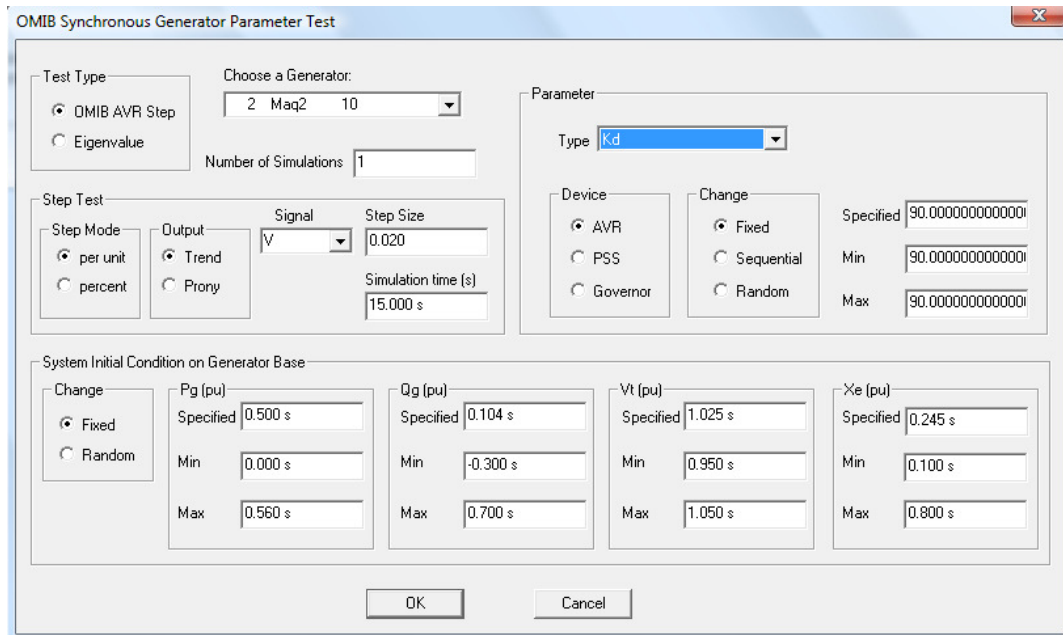


Figura IV–2 Interface de simulação

O arquivo de saída da resposta no tempo é formado por uma tabela de duas colunas, sendo a primeira coluna com os dados do tempo e a segunda com os valores da grandeza escolhida para análise.

O arquivo de saída no formato “Prony” tem a forma de uma tabela, onde cada linha corresponde a um caso simulado, sendo formada pelo código interno da grandeza modificada no regulador em análise, o valor numérico do parâmetro, a potência ativa em MW, a potência reativa em Mvar, o módulo da tensão terminal em pu, a impedância de acoplamento do sistema em pu, o erro da estimação de Prony, cinco conjuntos de frequência, amplitude e amortecimento do espectro de Prony, erro da estimação de Fourier, e cinco conjuntos de frequência e amplitude do espectro de Fourier, como descrito na Tabela IV–1.

Tabela IV-1 Índices gerados pelo ambiente de simulação.

Coluna	Parâmetro	Descrição
1	Índice do parâmetro	Identificação do parâmetro (ganho, constante de tempo, etc.)
2	Valor do parâmetro	Valor numérico para a simulação específica
3	P	MW gerado
4	Q	MVAR gerado
5	Vt	Módulo da tensão terminal
6	Xe	Reatância de Acoplamento com o sistema
7	Erro da estimação de Prony	Soma dos quadrados das diferenças observado e estimado
8	Frequência de Prony 1	Frequência do 1º modo
9	Amortecimento de Prony 1	Amortecimento do 1º
10	Amplitude de Prony 1	Amplitude do 1º modo
11	Frequência de Prony 2	Frequência do 2º modo
12	Amortecimento de Prony 2	Amortecimento do 2º modo
13	Amplitude de Prony 2	Amplitude do 2º modo
...
20	Frequência de Prony 5	Frequência do 5º modo
21	Amortecimento de Prony 5	Amortecimento do 5º modo
22	Amplitude de Prony 5	Amplitude do 5º modo
23	Erro da estimação de Fourier	Soma dos quadrados das diferenças observado e estimado
24	Frequência de Fourier 1	Frequência do modo de maior amplitude
25	Amplitude de Fourier 1	Amplitude do maior modo
26	Frequência de Fourier 2	Frequência do segundo modo de maior amplitude
27	Amplitude de Fourier 2	Amplitude do segundo modo
...
32	Frequência de Fourier 5	Frequência do quinto modo de maior amplitude
33	Amplitude de Fourier 5	Amplitude do quinto modo

IV.3 Construção das Bases de Treinamento

Os dados de treinamento são obtidos a partir da simulação do programa ORGANON, para diferentes condições de operação, da aplicação de um degrau na referência do regulador de tensão com o sistema equivalente. Nestes casos, são disponibilizadas a tensão terminal, a potência ativa e a corrente da armadura do gerador, sendo observada uma grandeza por conjunto de simulações. O sinal escolhido para a análise será decomposto no espectro de frequência através dos métodos de Prony e Fourier, gerando os índices que serão armazenados nos conjuntos de treinamento para a rede neural.

Os padrões correspondentes a situações onde o gerador apresenta operação normal (ausência de defeito) são obtidos aplicando-se o degrau na referência do regulador de tensão para diferentes cenários de operação do gerador, que são obtidos através de diferentes combinações de valores para a sua tensão terminal, potência ativa gerada e impedância de acoplamento com o sistema. Desta forma busca-se cobrir, de forma representativa, os cenários de operação aos quais o gerador pode estar submetido.

Os mesmos cenários operativos são considerados para a construção dos padrões de treinamento correspondentes a situações de defeito. Porém, neste caso, a degradação nos sistemas de controle é representada por variações nos parâmetros do regulador de tensão, do regulador de velocidade ou do sinal adicional estabilizador (PSS), sendo avaliado um equipamento por vez.

As bases de treinamento para as redes neurais serão, portanto, compostas por padrões correspondentes a situações de operação normais e degradadas (anormais) de cada regulador. Neste caso, será construídos diferentes classificadores neurais, cada um responsável por detectar condições anormais de operação em um sistema de controle específico.

Cada registro do conjunto de treinamento é composto por uma lista de parâmetros que definem o ponto de operação do gerador, o espectro de frequência da

grandeza em análise, que pode ser por Prony ou Fourier, para a resposta da máquina ao teste de degrau no regulador de tensão.

Conforme já mencionado, foram definidos alguns parâmetros cuja variação pudesse representar um espectro bem amplo das condições operativas da máquina. O primeiro parâmetro corresponde ao despacho de potência ativa (P_g), o segundo a tensão terminal (V_t) e o terceiro à reatância externa de conexão com a barra infinita (X_e). A interpretação dos dois primeiros parâmetros é trivial. Já a reatância externa representa o grau de acoplamento da unidade geradora ao resto do sistema elétrico. Um valor alto para essa reatância representa uma ligação fraca, ou seja, o gerador está mais afastado do sistema elétrico. Isto pode ocorrer, por exemplo, em decorrência da saída de serviço de linhas de transmissão na vizinhança ou na subestação de conexão do gerador. O conjunto de treinamento contém as informações correspondentes ao desempenho da máquina em condição normal e de defeito.

As situações de operação nas quais o regulador de tensão apresenta defeito, são representadas por padrões obtidos variando-se não apenas as condições de operação da máquina (tensão terminal, potência ativa e impedância de ligação) como também o parâmetro K_d do regulador, ilustrado no diagrama de blocos da Figura IV-3.

No caso do regulador de velocidade, as situações de defeito são obtidas também por simulação, variando-se o valor do ganho K_a da Figura IV-4 para diferentes condições de operação da máquina. Já para o PSS, Figura IV-5, foi alterado o valor do ganho K_2 para diferentes condições de operação da máquina.

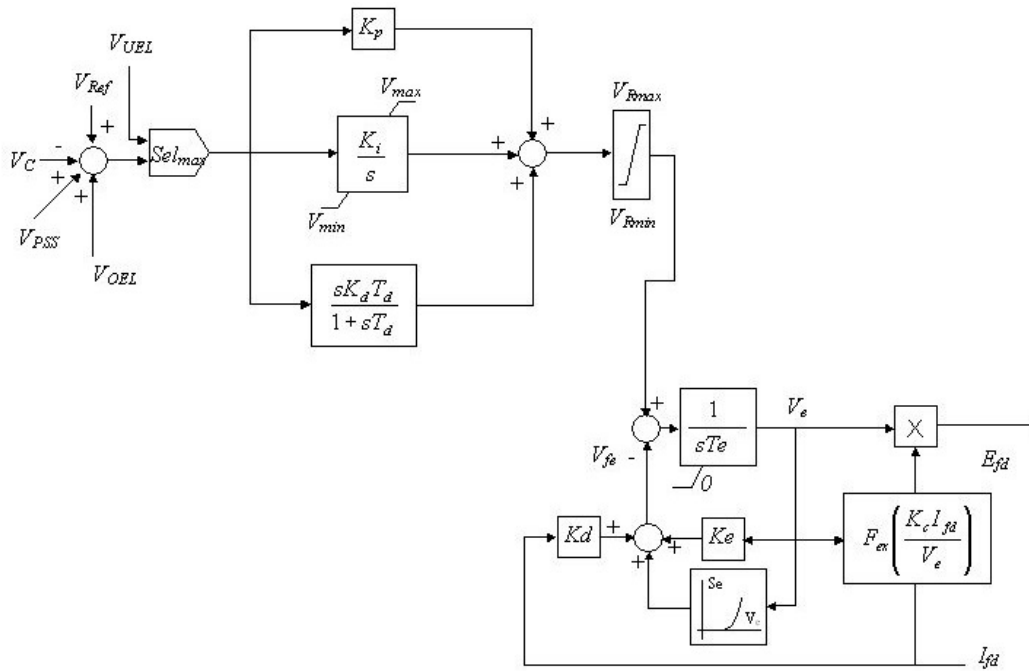


Figura IV-3 Diagrama de blocos do regulador de tensão

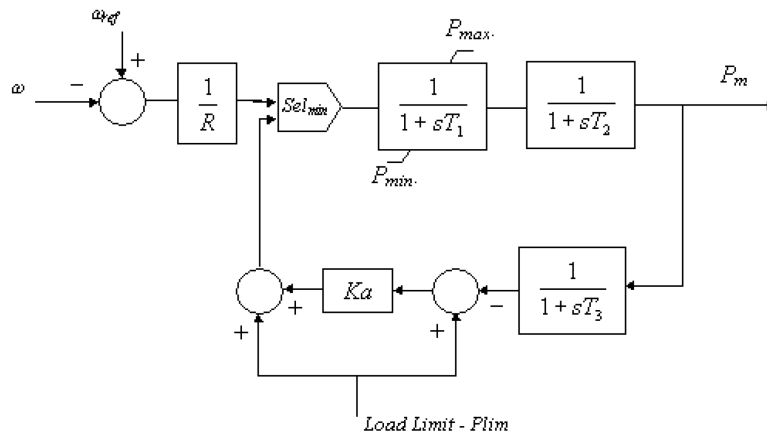


Figura IV-4 Diagrama de blocos do regulador de velocidade

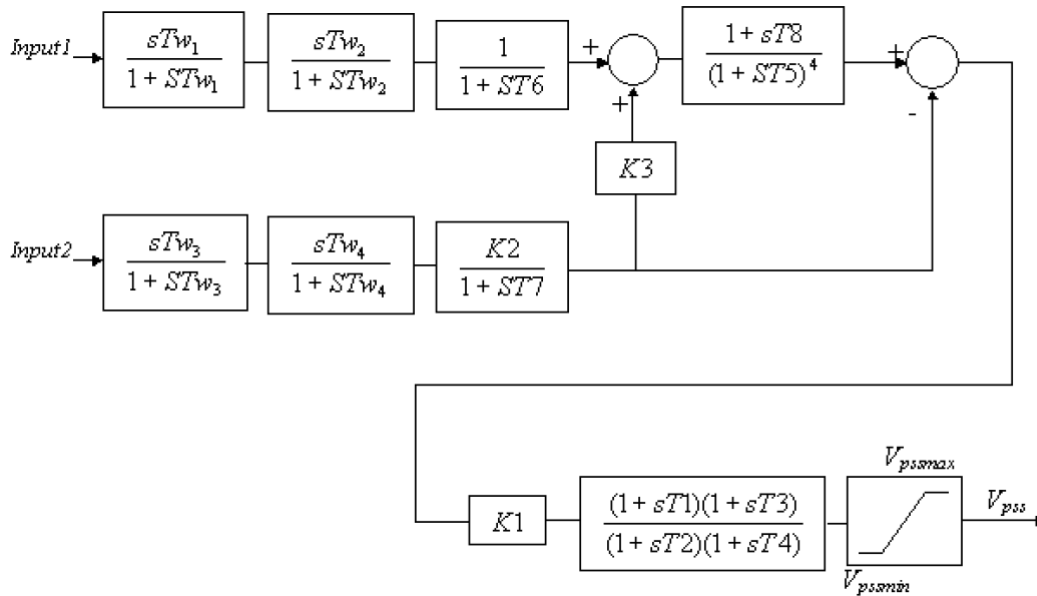


Figura IV-5 Diagrama de blocos do sinal adicional estabilizador

Neste trabalho será investigada a adequação das respostas fornecidas pelos métodos de Prony e de Fourier para a representação de padrões que reflitam o desempenho do gerador sob diferentes condições de operação, de forma a se identificar situações onde os sistemas de controle encontram-se degradados. Dessa maneira, as saídas obtidas das simulações do ORGANON, que contêm as informações do ponto de operação do gerador e o espectro de frequência de Prony e Fourier, devem ser utilizadas em bases de dados distintas, uma com o espectro de Prony e a outra com o espectro de Fourier. Isto deve ser feito de forma que os padrões de desempenho da máquina, obtidos quando se emprega cada um dos dois métodos, possam ser utilizados separadamente para o treinamento de diferentes redes neurais e posteriormente comparados para determinar a forma de representação mais eficaz.

As bases de dados para o treinamento da rede neural com padrões obtidos utilizando-se o método de Prony são constituídas pelo ponto de operação do gerador e pelo espectro de Prony obtido para o sinal da grandeza que esta sendo monitorada

(tensão, potência ou corrente). Por outro lado, as bases de dados para o treinamento utilizando padrões obtidos com o método de Fourier são constituídas pelo ponto de operação do gerador e pelo espectro de Fourier obtido para o sinal da grandeza monitorada. A Tabela IV-2 e a Tabela IV-3 mostram as variáveis que compõem os padrões de entrada em cada caso.

Tabela IV-2 Variáveis de entrada – Pré-processamento via método de Prony

Coluna	Parâmetro	Descrição
1	P	MW gerado
2	Q	MVAR gerado
3	Vt	Módulo da tensão terminal
4	Xe	Reatância de Acoplamento com o sistema
5	Frequência de Prony 1	Frequência do 1º modo
6	Amortecimento de Prony 1	Amortecimento do 1º
7	Amplitude de Prony 1	Amplitude do 1º modo
8	Frequência de Prony 2	Frequência do 2º modo
9	Amortecimento de Prony 2	Amortecimento do 2º modo
10	Amplitude de Prony 2	Amplitude do 2º modo
...
17	Frequência de Prony 5	Frequência do 5º modo
18	Amortecimento de Prony 5	Amortecimento do 5º modo
19	Amplitude de Prony 5	Amplitude do 5º modo

Tabela IV-3 Variáveis de entrada – Pré-processamento via método de Fourier

Coluna	Parâmetro	Descrição
1	P	MW gerado
2	Q	MVAR gerado
3	Vt	Módulo da tensão terminal
4	Xe	Reatância de Acoplamento com o sistema
5	Frequência da Fourier 1	Frequência do modo de maior amplitude
6	Amplitude da Fourier 1	Amplitude do maior modo
7	Frequência da Fourier 2	Frequência do segundo modo de maior amplitude
8	Amplitude da Fourier 2	Amplitude do segundo modo

13	Frequência da Fourier 5	Frequência do quinto modo de maior amplitude
14	Amplitude da Fourier 5	Amplitude do quinto modo

De forma a avaliar a qualidade de classificadores neurais para a identificação de condições anormais em um dado sistema de controle do gerador (regulador de tensão, regulador de velocidade ou PSS), cujos padrões de entrada podem ser construídos a partir da observação de diferentes variáveis (tensão, potência ou corrente), as quais por sua vez podem ser processadas utilizando o método de Fourier ou de Prony, diferentes bases de dados para treinamento devem ser criadas. Tais bases de dados para treinamento são descritas na Tabela IV-4. Exemplificando a nomenclatura adotada, o conjunto de treinamento **RT_Prony_V** contém dados das simulações realizadas considerando defeitos no regulador de tensão, cujo sinal a ser analisado é a tensão terminal do gerador, observado no tempo e processado utilizando o método de Prony.

Tabela IV-4 Bases de dados para treinamento

Base de Dados	Regulador	Método	Grandeza
RT_Prony_V	Tensão	Prony	Tensão
RT_Prony_P	Tensão	Prony	Potência
RT_Prony_I	Tensão	Prony	Corrente
RT_Fourier_V	Tensão	Fourier	Tensão
RT_Fourier_P	Tensão	Fourier	Potência
RT_Fourier_I	Tensão	Fourier	Corrente
RV_Prony_V	Velocidade	Prony	Tensão
RV_Prony_P	Velocidade	Prony	Potência
RV_Prony_I	Velocidade	Prony	Corrente
RV_Fourier_V	Velocidade	Fourier	Tensão
RV_Fourier_P	Velocidade	Fourier	Potência
RV_Fourier_I	Velocidade	Fourier	Corrente
PSS_Fourier_V	PSS	Prony	Tensão
PSS_Prony_P	PSS	Prony	Potência
PSS_Prony_I	PSS	Prony	Corrente
PSS_Prony_V	PSS	Fourier	Tensão
PSS_Fourier_P	PSS	Fourier	Potência
PSS_Fourier_I	PSS	Fourier	Corrente

IV.4 Seleção do Modelo Neural

Uma vez que a Rede Neural Artificial MLP utiliza treinamento supervisionado, para cada padrão de entrada considerado no conjunto de treinamento estará associada uma saída desejada, previamente conhecida, a qual indicará se um padrão está associado a um desempenho normal ou anormal da máquina.

Na investigação do modelo neural que melhor se ajusta aos dados contidos em cada conjunto de treinamento será adotada a seguinte estratégia durante o processo de aprendizagem:

- ✓ **Arquitetura da rede:** como a grande maioria dos problemas práticos é resolvida com apenas uma camada escondida de neurônios, segundo o teorema da aproximação universal, [48]. Serão realizados testes considerando, durante o treinamento, uma única camada interna de neurônios e diferentes quantidades de neurônios em tal camada.
- ✓ **Função de ativação:** Será utilizada a função sigmóide logística para a ativação dos neurônios da rede.
- ✓ **Inicialização dos pesos da rede:** De forma a reduzir o risco de convergência para ótimos locais indesejáveis, serão testados diferentes valores iniciais para os pesos da rede.
- ✓ **Forma de apresentação dos padrões de entrada:** Será adotada a apresentação por lote.
- ✓ **Taxa de Aprendizagem:** será adotada uma taxa de aprendizado adaptativa, ou seja, capaz de ser automaticamente aumentada ou diminuída em função da taxa

de decaimento do erro global medido na saída da rede, visando assim acelerar o processo de aprendizagem.

- ✓ **Critério de parada:** será adotado inicialmente como critério de parada um número máximo (previamente definido) de apresentações de lotes de padrões de entrada à rede. No caso de verificação de super-ajuste da rede aos dados durante o aprendizado, diferentes valores do erro alvo para treinamento serão testados como critério de parada.

O desempenho de cada modelo neural construído pode ser aferido a partir dos resultados obtidos após a fase de treinamento. Neste caso, pretende-se utilizar as seguintes medidas de desempenho:

Taxa de sucessos: índice que mede a capacidade da rede identificar corretamente a condição de operação da máquina (normal ou anormal).

Taxa de falhas: Índice que mede o risco de se ter uma indicação incorreta da condição de operação da máquina, podendo estar associado a situações de falso alarme ou de não detecção de problemas operativos.

Incapacidade de diagnóstico: Associado a situações nas quais a rede não é capaz de classificar a condição de operação da máquina como normal ou anormal.

Os índices de desempenho podem ser obtidos tanto para avaliar o desempenho para o conjunto de treinamento utilizado quanto para outros padrões não considerados no treinamento da rede.

IV.5 Obtenção das Classificações

A saída y_k de cada neurônio da última camada da rede detecta ou rejeita a ocorrência de uma falta no componente específico. Logo, durante a fase de treinamento as seguintes saídas desejadas são utilizadas:

- $Yd_k = 0,1$, se o desempenho do sistema de controle é anormal; ou
- $Yd_k = 0,9$, se o desempenho do sistema de controle está normal.

Os valores 0,1 e 0,9 foram utilizados para representar as saídas binárias no lugar de 0,0 e 1,0 para evitar as regiões de saturação da função de ativação sigmóide utilizada neste trabalho.

Uma vez treinada, a RNA pode ser utilizada para fornecer classificações a partir do processamento de um padrão de comportamento observado. Cada padrão k apresentado será classificado em função da resposta obtida na saída da rede neural, de acordo com o seguinte critério:

Durante o processo de classificação, o seguinte diagnóstico é assumido para cada componente, após a análise da saída produzida pelo neurônio correspondente:

- $a_1 \leq y_k < a_2$ O padrão k corresponde a um desempenho alterado do sistema de controle;
- $b_1 < y_k \leq b_2$ O padrão k corresponde a um desempenho normal do sistema de controle;
- $a_2 \leq y_k \leq b_1$ Não é possível classificar o desempenho do sistema de controle a partir do padrão observado.

As faixas acima são utilizadas porque as saídas obtidas não serão exatamente as saídas desejadas utilizadas durante a fase de treinamento e visando minimizar o número de classificações incorretas. Os valores a_1 , a_2 , b_1 e b_2 devem ser obtidos por observação durante os testes com as redes treinadas, sendo que:

- $a_1 \leq Yd_k = 0,1 \leq a_2$;
- $b_1 \leq Yd_k = 0,9 \leq b_2$.

IV.6 Avaliação de Desempenho das Redes Neurais

A capacidade de aprendizagem das redes neurais pode ser avaliada através dos índices de desempenho apresentados a seguir:

- Classificação Correta (%) – casos nos quais a classificação do desempenho do gerador, realizada pela rede neural, foi correta.

$$CC (\%) = \frac{NCC}{NP} \times 100 \quad (IV-1)$$

onde:

CC(%) – percentual de classificações corretas

NCC – número total de classificações corretas

NP – número total de padrões testados

- Classificação Incorreta (%) - casos nos quais a classificação do desempenho do gerador, realizada pela rede neural, não foi correta.

$$CI (\%) = \frac{NCI}{NP} \times 100 \quad (IV-2)$$

Onde:

CI(%) – percentual de classificações incorretas

NCI – número total classificações incorretas

NP – número total de padrões testados

- Classificação Indeterminada (%) - casos nos quais não foi possível classificar o desempenho do gerador a partir dos padrões apresentados.

$$CIND (\%) = \frac{NCIND}{NP} \times 100 \quad (IV-3)$$

Onde:

CIND(%) – percentual de classificações indeterminados

NCIND – número total de classificações indeterminadas observadas

NP – número total de padrões testados

IV.7 Conclusões

Este capítulo apresentou a metodologia empregada para a construção de classificadores neurais responsáveis por fornecer diagnósticos sobre a condição de operação dos sistemas de controle de geradores elétricos. Foi apresentada a forma como simulações são realizadas com o auxílio do simulador computacional desenvolvido no programa ORGANON, visando à construção de bases de dados destinadas ao treinamento das RNAs.

Foi definida também a estratégia de treinamento a ser implementada para a construção do modelo neural responsável pela análise do padrão de comportamento do gerador. Além disso, foi apresentado também como será realizado o processo de classificação dos padrões, bem como a avaliação do desempenho da RNA treinada.

No próximo capítulo serão descritos os parâmetros envolvidos no processo de treinamento e apresentados os resultados de testes com as RNAs responsáveis pela classificação do comportamento do gerador. Será possível comparar a representação dos padrões de comportamento através dos métodos de Prony e de Fourier, avaliando capacidade destas técnicas representarem adequadamente os padrões de resposta de um gerador, assim como avaliar a viabilidade de utilização de uma rede neural para realizar o reconhecimento de tais padrões. Além disso, em função dos resultados obtidos, será possível também avaliar a qualidade da informação contida em cada variável monitorada (tensão, potência ou corrente) e utilizada para a extração dos padrões.

No Capítulo V serão apresentadas as simulações realizadas e os resultados dos testes obtidos com os classificadores construídos.

* * *

Capítulo V

Testes e Resultados

V.1 Introdução

Neste capítulo será apresentada uma descrição das simulações realizadas para a construção das bases de treinamento de classificadores neurais responsáveis pelo diagnóstico das condições de operação do gerador, bem como os testes e resultados obtidos com os classificadores construídos. Para a construção das bases de treinamento foi utilizado o simulador descrito no capítulo anterior, onde foi aplicado um degrau de 0,02pu na referência do regulador de tensão do gerador. Diversas situações de operação foram consideradas, correspondendo a diferentes condições de despacho de geração, de tensão terminal, do acoplamento com o sistema elétrico, etc. Para tais situações foi observado o comportamento da máquina na ausência de defeitos em seus componentes, assim como considerando defeitos no regulador de tensão, no regulador de velocidade e no PSS. Para representar a degradação nos sistemas de controle do gerador, os parâmetros do mesmo sofreram uma variação linear, variando de zero ao dobro do valor definido no regulador.

Utilizou-se o espectro de Prony e o espectro de Fourier para obter os padrões de frequência para a análise e registro do comportamento da máquina frente às diferentes situações de operação.

Com relação à RNA, será apresentada a estratégia empregada para a investigação e definição do modelo mais adequado ao processo de inferência sobre as condições de operação da máquina em análise. A RNA empregada é a Perceptron de

Múltiplas Camadas, cujo modelo estará completamente descrito após a definição de sua arquitetura, modelo dos neurônios e pesos sinápticos (definidos somente após a conclusão da etapa de treinamento). Durante a fase de treinamento das redes neurais é utilizado o algoritmo da retropropagação dos erros. A forma como os parâmetros de treinamento serão explorados para se obter o melhor modelo possível também será apresentada e discutida. Para o treinamento e validação da rede neural foi utilizado o programa MATLAB.

V.2 Descrição do Gerador Utilizado para Teste

Nas simulações para obter os padrões de treinamento para a rede neural foi utilizado um gerador de uma usina termoelétrica, que no caso em estudo foi o da UTE TermoCeará. A Tabela V-1 apresenta os dados deste gerador. Como já informado nesta dissertação foram avaliados o regulador de tensão, o regulador de velocidade e o PSS. Os parâmetros do regulador de tensão da UTE TermoCeará, Figura IV-3, estão definidos na Tabela V-2. Para o modelo do regulador de velocidade, Figura IV-4, os parâmetros utilizados foram os definidos na

Tabela V-3. E para o modelo do PSS, Figura IV-5, os parâmetros definidos na Tabela V-4 foram utilizados para a análise.

Tabela V-1 Dados do gerador térmico

Parâmetro	Descrição	Valor	Unidade
Xd	Reatância Síncrona do Eixo de Direto	2,35	pu
X'd	Reatância Transitória de Eixo Direto	0,245	pu
X''d	Reatância Subtransitória de Eixo Direto	0,181	pu
Xq	Reatância síncrona de eixo em quadratura	2,15	pu
X'q	Indutância transitória de eixo em quadratura	0,181	pu
Xl	Reatância de Dispersão da Armadura	0,32	pu
Ra	Resistência do enrolamento de armadura	0,0	pu
T'd0	Constante de tempo transitória de eixo direto	9,67	s
T''d0	Constante de tempo subtransitória de eixo direto	0,05	s
T'q0	Constante de tempo transitória de eixo em quadratura	0,05	s
H	Constante de inércia	1,787	s
Damping	Constante de amortecimento	0,0	pu/pu
Base	Potência Nominal do Gerador	71,17	MVA
Ag	Coefficiente de Saturação	0,003	pu
Bg	Coefficiente de Saturação	0,006	pu

Tabela V-2 Dados do regulador de tensão do gerador térmico

Parâmetro	Valor	Unidade
Kd	90,0	pu
Td	0,10	pu
Ki	2,22	pu
Kp	25,2	pu
Vmax	50,6	pu
Vmin	-20,0	pu
Te	1,30	pu
Kc	0,19	pu

Parâmetro	Valor	Unidade
Kd	1,12	pu
Ke	1,0	pu
E1	3,0	pu
S(E1)	0,0018	pu
E2	4,0	pu
S(E2)	0,0037	pu
VRmax	50,60	pu
VRmin	0,00	pu

Tabela V-3 Dados do regulador de velocidade do gerador térmico

Parâmetro	Valor	Unidade	Parâmetro	Valor	Unidade
R	0,05	pu/pu	Plim	0,77	pu
T1	0,025	s	Ka	1,30	pu
T2	0,025	s	Pmax	0,77	pu
T3	0,75	s	Pmin	0,00	pu

Tabela V-4 Dados do PSS do gerador térmico

Parâmetro	Valor	Unidade	Parâmetro	Valor	Unidade
T1	0,20	s	Tw3	2,00	s
T2	0,02	s	Tw4	0,02	s
T3	0,20	s	K1	1,00	pu
T4	0,02	s	K2	0,559	pu
T5	0,10	s	K3	1,0	pu
T6	0,02	s	Vmin	-0,10	pu
T7	2,00	s	Vmax	0,10	pu
T8	0,50	s	Type	1	-
Tw1	2,00	s	Type	3	-
Tw2	2,00	s			

V.3 Simulação das Situações de Operação

A definição de um conjunto adequado de simulações para a montagem dos conjuntos de treinamento para a rede neural é fundamental para o desempenho da mesma. Portanto, é de suma importância que os casos sejam montados de forma a garantir o aprendizado da RNA.

As simulações foram realizadas com o sistema definido na Seção IV.2 do Capítulo IV, no qual a unidade geradora está ligada a uma “barra infinita”, ou seja, uma barra cuja frequência e tensão não variam, através de uma impedância de acoplamento, cujo valor utilizado foi à sua reatância transitória de eixo direto ($X'd$). A simulação consiste então na aplicação de um degrau de 0,02pu na referência do regulador de tensão, sendo monitoradas três grandezas, que são a tensão terminal, a potência ativa e a corrente da armadura do gerador. Para a construção de cada base de treinamento é considerado o sinal da resposta obtida para uma grandeza específica. O sinal escolhido para a análise é decomposto no espectro de frequência através dos métodos de Prony e Fourier, gerando os índices que serão armazenados nos conjuntos de treinamento para a rede neural, descritos no Capítulo IV. Cada registro do conjunto de treinamento é composto por uma lista de parâmetros que definem o ponto de operação do gerador e o espectro de frequência da grandeza em análise, que pode corresponder ao método de Prony ou de Fourier, para a resposta da máquina ao teste de degrau.

Para a construção das bases de treinamento para diagnóstico sobre o desempenho do regulador de tensão, foram realizadas simulações de operação sem defeito e com defeito. Para tal, variou-se o ponto de operação do gerador através da modificação da tensão terminal, da potência ativa e da impedância de ligação do gerador com o sistema. A variação do ponto de operação foi de forma aleatória definindo apenas a faixa de variação de cada parâmetro. Para os casos com defeito, além da variação do ponto de operação, o parâmetro K_d do regulador de tensão, Figura IV-3, sofreu também uma variação linear, tendo assumido valores de zero ao dobro do valor definido no regulador.

As simulações realizadas estão apresentadas na Tabela V-5. A primeira coluna define a quantidade de simulações em cada caso, a segunda o valor do ganho do regulador de tensão (K_d) utilizado nas simulações, a terceira a potência ativa em pu do gerador, a quarta a tensão terminal em pu, a quinta a reatância de acoplamento e a última coluna a classificação correspondente a cada caso. Ressalta-se que estas simulações foram realizadas para a avaliação da anormalidade a partir da observação do

sinal da tensão terminal, potência ativa e corrente, sendo avaliada uma por vez. Lembar-se que para o treinamento da rede neural foi utilizada um total de 20% dos casos simulados e os demais casos foram utilizados para a validação da rede, sendo estes considerados casos inéditos para a rede.

Tabela V-5 Simulações para obtenção da base de treinamento para o RT

Quantidade de Casos	Kd	Pg (pu)	V (pu)	Xe (pu)	Classificação
40	90	0 a 1,0	1,00	0,245	Sem defeito
40	90	0,5	0,95 a 1,05	0,245	Sem defeito
39	90	0,5	1,0	0,1 a 0,8	Sem defeito
100	0 a 180	0 a 1,0	1,00	0,245	Com defeito
100	0 a 180	0,5	0,95 a 1,05	0,245	Com defeito
100	0 a 180	0,5	1,0	0,1 a 0,8	Com defeito

No caso do regulador de velocidade, foram consideradas as mesmas simulações realizadas para a avaliação do regulador de tensão, no que diz respeito às variações no ponto de operação e definição dos casos sem defeito. A simulação de casos com defeito no regulador de velocidade foi realizada alterando-se o valor do ganho Ka do regulador de velocidade, Figura IV-4. A Tabela V-6 apresenta uma descrição das simulações realizadas para a construção do conjunto de treinamento para a avaliação de desempenho do regulador de velocidade. Deve-se ressaltar que três bases de treinamento distintas serão construídas a partir de tais simulações, uma vez que se deseja avaliar a utilização dos sinais de tensão, potência e corrente para a definição dos padrões de entrada. Da mesma forma que o regulador de tensão, foi utilizado um total de 20% dos casos simulados para o treinamento da rede neural e os demais casos foram utilizados para a validar a rede, sendo estes considerados casos inéditos para a rede.

Tabela V-6 Simulações para obtenção da base de treinamento para o RV

Quantidade de Casos	Ka	Pg (pu)	V (pu)	Xe (pu)	Classificação
40	1,3	0 a 1,0	1,00	0,245	Sem defeito
40	1,3	0,5	0,95 a 1,05	0,245	Sem defeito
39	1,3	0,5	1,0	0,1 a 0,8	Sem defeito
100	0 a 5,0	0 a 1,0	1,00	0,245	Com defeito
98	0 a 5,0	0,5	0,95 a 1,05	0,245	Com defeito
99	0 a 5,0	0,5	1,0	0,1 a 0,8	Com defeito

Para o PSS, da mesma forma que para os reguladores de tensão e de velocidade, foram realizadas as mesmas simulações para a definição dos casos sem anormalidade. A simulação de casos de anormalidade no PSS foi realizada alterando-se o valor do ganho K_2 do PSS, Figura IV-5. A Tabela V-7 apresenta um resumo das simulações realizadas para a construção do conjunto de treinamento para a avaliação de desempenho do PSS. Deve-se ressaltar que três bases de treinamento distintas serão construídas a partir de tais simulações, considerando, respectivamente, a observação dos sinais de tensão, potência e corrente para a definição dos padrões de entrada. Da mesma forma que os casos com o regulador de tensão e velocidade fo utilizado um total de 20% dos casos simulados para o treinamento da rede neural e os demais casos foram utilizados para a validar a rede, sendo estes considerados casos inéditos para a rede.

Tabela V-7 Simulações para o treinamento da RNA do PSS

Quantidade de Casos	K2	Pg (pu)	V (pu)	Xe (pu)	Classificação
40	0,559	0 a 1,0	1,00	0,245	Sem defeito
40	0,559	0,5	0,95 a 1,05	0,245	Sem defeito
39	0,559	0,5	1,0	0,1 a 0,8	Sem defeito
98	0 a 5,0	0 a 1,0	1,00	0,245	Com defeito
97	0 a 5,0	0,5	0,95 a 1,05	0,245	Com defeito
100	0 a 5,0	0,5	1,0	0,1 a 0,8	Com defeito

V.4 Treinamento dos Classificadores Neurais

Conforme já mencionado, foi utilizado o método da retropropagação dos erros para o treinamento das redes neurais MLP utilizadas neste trabalho. Durante a fase de treinamento foram investigadas diversas arquiteturas para as redes neurais, visando encontrar o melhor desempenho das mesmas. Foram utilizados 19 nós para as redes neurais cujos padrões de entrada são obtidos utilizando o método de Prony e 14 nós de entrada quando os padrões são obtidos empregando-se o método de Fourier. Em todos os casos foi utilizado um único neurônio de saída (responsável por indicar a operação normal ou anormal do sistema de controle monitorado) e uma única camada escondida de neurônios, sendo testadas nesta camada diferentes quantidades de neurônios.

Em cada iteração do processo de treinamento e atualização dos pesos das conexões da rede, os padrões foram apresentados em forma de lote, este correspondendo ao total de padrões na base de treinamento. Foi adotada uma taxa de aprendizagem

adaptativa e o critério de parada para o treinamento foi o número máximo de apresentações de lotes de padrões de entrada à rede. Na maioria dos casos foi adotado um total de 100.000 iterações para a interrupção do treinamento, tendo este número sido variado em alguns casos de forma a se obter um melhor desempenho da rede quando da apresentação de padrões inéditos na fase de validação do treinamento. Esta base de treinamento foi apresentada ao MATLAB para obter a rede neural treinada.

A Tabela V-8 resume os parâmetros utilizados no treinamento dos diferentes classificadores neurais investigados neste trabalho, visando o sucesso na de detecção de anormalidades no regulador de tensão, no regulador de velocidade e no PSS.

Tabela V-8 Classificadores de desempenho da RNA para os reguladores

Classificador	Entrada	Camada de neurônios		Pesos iniciais	Lote	Parada
		Saída	Escondida			
Prony_V	19	1	5, 10, 15, 20, 25, 30 e 35	Aleatórios	Conjunto	Nº máximo de iterações
Prony_P	19	1	5, 10, 15, 20, 25, 30 e 35	Aleatórios	Conjunto	Nº máximo de iterações
Prony_I	19	1	5, 10, 15, 20, 25, 30 e 35	Aleatórios	Conjunto	Nº máximo de iterações
FFT_V	14	1	5, 10, 15, 20, 25, 30 e 35	Aleatórios	Conjunto	Nº máximo de iterações
FFT_P	14	1	5, 10, 15, 20, 25, 30 e 35	Aleatórios	Conjunto	Nº máximo de iterações
FFT_I	14	1	5, 10, 15, 20, 25, 30 e 35	Aleatórios	Conjunto	Nº máximo de iterações

V.5 Obtenção de Classificações

No problema tratado, cada rede neural terá um neurônio de saída, o qual será responsável por associar um dado padrão de entrada observado a um desempenho normal ou anormal de um dos sistemas de controle do gerador. Dessa maneira, são utilizadas saídas binárias, sendo empregada a função de ativação sigmóide logística no neurônio de saída e nos demais neurônios da rede MLP. Nestes casos, levando-se em consideração o exposto na Seção III.6, cada padrão k observado será classificado conforme a saída y_k obtida pela rede neural, de acordo com o seguinte critério:

- $0,8 < y_k < 1,0$ o desempenho é considerado normal;
- $0,0 < y_k < 0,2$ o desempenho é considerado anormal;
- $0,2 \leq y_k \leq 0,8$ Não é possível classificar o desempenho.

Neste caso, os limiares de cada classe foram definidos em função das simulações realizadas e de forma a reduzir a quantidade de classificações incorretas.

V.6 Resultados

Através da variação da arquitetura da rede e dos parâmetros de treinamento, diversos modelos foram testados para cada conjunto de treinamento. Dentre os vários modelos testados, são apresentados na Tabela V-9 os resultados obtidos para diagnóstico no regulador de tensão, na Tabela V-11 os resultados para o regulador de velocidade e na Tabela V-13 os resultados para o PSS. Ressalta-se que os resultados apresentados nas tabelas correspondem aos modelos neurais que apresentaram melhor

desempenho quando submetidos a um conjunto de 330 padrões, 160 deles inéditos (não apresentados durante o treinamento), utilizados para testar cada rede treinada. Nas tabelas a seguir, o desempenho de cada classificador é medido utilizando-se os indicadores definidos no Capítulo IV.

Tabela V-9 Resultados para o conjunto de treinamento para o RT

Classificador	Entrada	Camada de neurônios		CC (%)	CI (%)	CIND (%)
		Saída	Escondida			
RT_Prony_V	19	1	5	100,00	0,00	0,00
RT_Prony_P	19	1	10	100,00	0,00	0,00
RT_Prony_I	19	1	20	100,00	0,00	0,00
RT_FFT_V	14	1	20	82,52	0,00	17,48
RT_FFT_P	14	1	30	96,21	1,72	2,07
RT_FFT_I	14	1	25	80,75	0,00	19,25

Tabela V-10 Resultados para o conjunto de testes para o RT

Classificador	Entrada	Camada de neurônios		CC (%)	CI (%)	CIND (%)
		Saída	Escondida			
RT_Prony_V	19	1	15	93,90%	0,00	6,10
RT_Prony_P	19	1	10	100,00	0,00	0,00
RT_Prony_I	19	1	25	97,73	0,00	2,27%
RT_FFT_V	14	1	20	55,49	0,00	44,51
RT_FFT_P	14	1	20	86,89	2,19	10,93
RT_FFT_I	14	1	25	49,24	1,52	49,24

Tabela V-11 Resultados para o conjunto de treinamento para o RV

Classificador	Entrada	Camada de neurônios		CC (%)	CI (%)	CIND (%)
		Saída	Escondida			
RV_Prony_V	19	1	15	100,00	0,00	0,00
RV_Prony_P	19	1	10	100,00	0,00	0,00
RV_Prony_I	19	1	20	100,00	0,00	0,00
RV_FFT_V	14	1	25	97,23	0,00	2,77
RV_FFT_P	14	1	20	100,00	0,00	0,00
RV_FFT_I	14	1	15	96,83	0,00	3,17

Tabela V-12 Resultados para o conjunto de testes para o RV

Classificador	Entrada	Camada de neurônios		CC (%)	CI (%)	CIND (%)
		Saída	Escondida			
RV_Prony_V	19	1	25	60,00	4,74	35,26
RV_Prony_P	19	1	35	76,67	6,19	17,14
RV_Prony_I	19	1	15	53,37	1,04	45,60
RV_FFT_V	14	1	20	26,32	0,00	73,68
RV_FFT_P	14	1	25	36,19	2,38	61,43
RV_FFT_I	14	1	20	24,35	2,07	73,58

Tabela V-13 Resultados para o conjunto de treinamento para o PSS

Classificador	Entrada	Camada de neurônios		CC (%)	CI (%)	CIND (%)
		Saída	Escondida			
PSS_Prony_V	19	1	20	100,00	0,00	0,00
PSS_Prony_P	19	1	25	100,00	0,00	0,00
PSS_Prony_I	19	1	30	100,00	0,00	0,00
PSS_FFT_V	14	1	25	98,48	0,00	1,52
PSS_FFT_P	14	1	20	100,00	0,00	0,00
PSS_FFT_I	14	1	20	93,95	0,00	6,05

Tabela V-14 Resultados para o conjunto de testes para o PSS

Classificador	Entrada	Camada de neurônios		CC (%)	CI (%)	CIND (%)
		Saída	Escondida			
PSS_Prony_V	19	1	30	75,85	6,28	17,87
PSS_Prony_P	19	1	35	79,05	0,00	20,95
PSS_Prony_I	19	1	35	75,24	0,48	24,29
PSS_FFT_V	14	1	30	52,66	3,86	42,03
PSS_FFT_P	14	1	15	71,43	0,00	28,57
PSS_FFT_I	14	1	25	44,29	7,14	48,57

Os seguintes comentários podem ser feitos a partir dos resultados apresentados e do conjunto de simulações realizadas:

- A quantidade de nós de entrada e de saída foi definida em função do número de variáveis de entrada presentes em cada base de treinamento e da filosofia de classificação binária proposta como resposta da rede;

- Os resultados apresentados nas tabelas correspondem às melhores arquiteturas. Foi possível observar durante as simulações que o emprego de arquiteturas diferentes das apresentadas levou, em geral, a um desempenho pior;
- Foi possível também observar que o emprego da taxa de aprendizagem adaptativa fez com que o valor inicial de tal taxa tivesse pouca influência sobre o processo de aprendizagem;
- Os padrões utilizados para testar as redes treinadas consistiram tanto de padrões presentes na base de treinamento quanto de padrões novos, nunca antes apresentados à rede;
- Os indicadores de desempenho obtidos mostraram que foi possível um melhor aprendizado sobre os conjuntos de treinamento onde os padrões de comportamento do gerador são representados utilizando a análise de Prony;
- A alta taxa de acertos (CC) e a baixa taxa de erros (CI) mostram ser viável a utilização de redes neurais para reconhecimento de padrões de comportamento do gerador, sendo tais padrões obtidos pelo pré-processamento da resposta da máquina utilizando-se o método de Prony;
- Observa-se na Tabela V-9 que na análise para o regulador de tensão o método de Prony apresenta um melhor desempenho e a grandeza monitorada que levou a 100% o índice de acertos é a potência elétrica, para uma quantidade maior de neurônios na camada escondida o resultado foi exatamente o mesmo para 10 neurônios;
- Para o regulador de velocidade, Tabela V-11, verifica-se que houve uma baixa taxa de acertos em relação ao obtido para o regulador de tensão, Tabela V-9, e uma alta taxa de casos indefinidos. Verifica-se também que o método de Prony apresenta um desempenho superior ao método de Fourier e a potência elétrica é a melhor grandeza para a identificação do defeito;

- No caso do PSS, Tabela V-13, verifica-se que o método de Prony é mais eficiente que o método de Fourier para a representação dos padrões e a grandeza com maior número de casos corretos é a potência elétrica;
- O alto número de casos incorretos no regulador de velocidade e no PSS pode ser explicado pelo tipo de evento utilizado em todas as simulações, que foi a aplicação de um degrau na referência do regulador de tensão;
- Os resultados obtidos para o conjunto de treinamento e de teste mostraram que foi possível obter boa capacidade de generalização quando se utilizou os padrões pré-processados pela Análise de Prony para a monitoração do regulador de tensão. O mesmo não ocorreu para a monitoração do regulador de velocidade e do PSS, tendo sido observada uma grande quantidade de classificações indeterminadas para os padrões de teste. Tal fato pode vir a ser contornado com uma redistribuição dos padrões pelos conjuntos de treinamento e teste ou pela redefinição dos limiares utilizados para a identificação de padrões de normalidade ou anormalidade no desempenho de tais controles. Todavia, conforme mencionado no comentário anterior, o tipo de teste aplicado pode ser um limitante para a obtenção de melhores desempenhos para a monitoração do regulador de velocidade e do PSS;
- O método de Prony mostrou ser mais eficiente que o método de Fourier no diagnóstico das condições anormais de operação do gerador em todas as avaliações, pois apresentou uma quantidade de acertos maior.

Como foi possível perceber das simulações até então realizadas e dos resultados apresentados, é proposta a utilização de redes neurais distintas para a monitoração de cada sistema de controle, ou seja, uma rede neural é responsável por detectar ou rejeitar a existência de problemas na atuação do regulador de tensão, enquanto outras redes neurais monitoram problemas relacionados à atuação do regulador de velocidade.

A aplicação da metodologia proposta neste trabalho para a monitoração do desempenho de um gerador pode ser sintetizada pelo diagrama apresentado na Figura V-1.

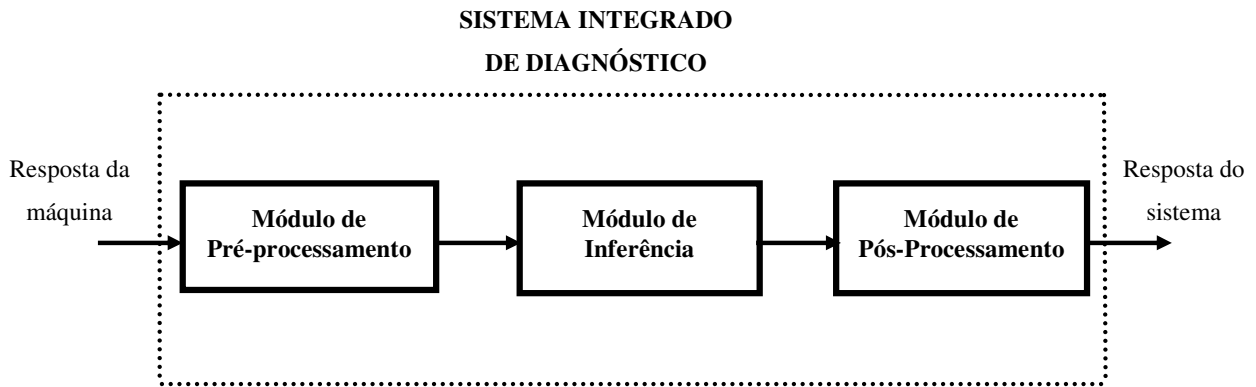


Figura V-1 Concepção de um sistema integrado de diagnóstico

No diagrama da Figura V-1 a resposta da máquina é representada pelo sinal de potência (resposta no tempo), observado após a aplicação de um degrau na referência de tensão do gerador, para uma dada condição de operação. No módulo de pré-processamento o sinal de potência é processado utilizando-se o método de Prony e, finalmente, um vetor de variáveis de entrada, Tabela IV-4, é apresentado ao módulo de inferência, para os classificadores RT_Prony_P, RV_Prony_P e PSS_Prony_P produzirem classificações quanto ao desempenho do regulador de tensão, do regulador de velocidade e do PSS, respectivamente. No módulo de pós-processamento as classificações obtidas pelas redes neurais são transformadas em diagnóstico sobre a condição de cada sistema de controle.

V.7 Conclusões

Este capítulo apresentou as simulações realizadas com o auxílio do simulador computacional apresentado com Capítulo IV, visando à construção de bases de dados destinadas ao treinamento das redes neurais artificiais responsáveis por detectar condições anormais de operação de geradores elétricos.

Como resultado deste trabalho, gerou-se dezoito bases de dados, referentes a diferentes condições de operação do gerador e para as quais se considerou a ausência ou a presença de anormalidade nos reguladores de tensão, de velocidade e PSS. Para o diagnóstico de anormalidade considerou-se também a observação do desempenho do gerador utilizando-se o método de Prony e o método de Fourier.

Foi definida também a estratégia de treinamento a ser implementada para a construção do modelo neural responsável pela análise do padrão de comportamento do gerador.

Foi possível comparar a representação dos padrões de comportamento através dos métodos de Prony e de Fourier, tendo o primeiro se mostrado mais adequado para a representação dos padrões de resposta de um gerador. Os resultados dos testes realizados mostraram ser viável a utilização de redes neurais artificiais para realizar a tarefa de reconhecimento de padrões desejada.

* * *

Capítulo VI

Conclusões

VI.1 Retrospectiva

O Capítulo I desta dissertação apresentou os conceitos básicos, metodologias para a detecção de falhas em geradores elétricos e o objetivo deste trabalho.

No Capítulo II foram abordados os métodos de processamento de sinais utilizados, sendo eles, o método de Prony e Fourier, os resultados comparativos entre os métodos e um exemplo ilustrativo.

No Capítulo III foi apresentado um breve histórico e características gerais das Redes Neurais Artificiais, assim como a rede perceptron de múltiplas camadas, utilizada nesta dissertação.

O Capítulo IV descreveu a metodologia adotada e a sistemática para obter os dados para o treinamento das redes neurais, além dos critérios para validação das mesmas.

No Capítulo V foram apresentadas as simulações e testes realizados, as classificações obtidas e as conclusões quanto aos melhores modelos, métodos para pré-processamento e grandeza a ser monitorada.

VI.2 Principais Conclusões

Esta dissertação apresentou uma metodologia baseada na utilização de redes neurais para o reconhecimento de padrões de anormalidade na operação de geradores elétricos. A forma como foi explorada a arquitetura dos modelos neurais propostos e os seus parâmetros de treinamento foi descrita, assim como foram apresentados indicadores de desempenho para avaliar a adequação de cada modelo neural ao problema tratado.

As principais conclusões obtidas foram:

1. A análise de Prony provou ser mais adequada do que a transformada rápida de Fourier para a representação dos padrões de comportamento dinâmico do gerador frente à situações operativas diversas;
2. O sinal de potência elétrica mostrou ser mais adequado que a tensão terminal e a corrente de armadura na identificação de anormalidades nos controladores;
3. Foi confirmada a viabilidade da utilização de redes neurais como mecanismo de inferência para o reconhecimento de padrões de desempenho alterado dos reguladores de tensão, de velocidade e PSS de geradores elétricos.

A primeira conclusão confirma a expectativa gerada em relação ao potencial de cada técnica, a partir da análise qualitativa de resultados obtidos quando da implementação e testes das duas técnicas de análise.

A segunda conclusão mostra que, além da análise de Prony se confirmar como a mais adequada, é possível associar, utilizando redes neurais, os padrões obtidos

utilizando tal técnica a condições operativas normais ou degradadas dos sistemas de controle de um gerador.

Como a metodologia proposta indica condições anormais de desempenho dos sistemas de controle do gerador, o que não necessariamente está associado a uma condição de defeito na máquina (embora este pode ser iminente), é possível, a partir dos resultados obtidos de sua aplicação prática, realizar ações de manutenção preditiva, evitando assim situações que causem uma súbita indisponibilidade do equipamento. Porém, as ações de manutenção podem também, ao mesmo tempo, ser interpretadas como corretivas, uma vez que o desempenho degradado de um ou mais sistemas de controle podem colocar em risco a operação do sistema ao qual o gerador encontra-se conectado.

VI.3 Perspectiva

Diante dos resultados apresentados nesta dissertação pode-se observar que em uma futura continuação deste trabalho podem ser desenvolvidas ferramentas para uso em tempo real, que possibilitem a identificação e o diagnóstico de defeitos e anormalidades na operação de geradores, de reguladores de tensão, de regulador de velocidade e PSS utilizando Redes Neurais Artificiais. Desta forma, pode-se ainda vislumbrar como trabalhos futuros:

- Treinamento da rede MLP para casos históricos da operação de geradores elétricos conectados ao sistema brasileiro;
- Utilizar outras funções de ativação nos neurônio da rede neural MLP, tais como tangente hiperbólico;

- Modificar o tipo de evento para a identificação de problemas no regulador de velocidade, pois o degrau no regulador de tensão mostrou-se ser pouco eficiente na identificação de anormalidades neste regulador. Em um trabalho futuro recomenda-se utilizar um degrau de pequeno valor na referência do regulador de velocidade;
- Identificar de forma detalhada a localização do defeito nos reguladores analisados de tal forma a identificar o parâmetro do regulador que esteja anormal;
- Treinamento de uma rede MLP para identificação de defeitos simultâneos em dois ou mais controladores;
- Construção de um sistema de diagnóstico que integra os módulos de Pré-processamento (análise de Prony), Inferência (rede MLP) e Pós-processamento (regras de decisão e apresentação de diagnósticos ao usuário), conforme ilustrado na Figura V-1, devendo ser utilizado um sistema especialista para o gerenciamento entre os três módulos apresentado, assim como para a interface com o operador;
- Avaliar a inferência através de outros modelos neurais, para avaliar qual modelo se adapta mais a este tipo de avaliação;
- Construção e utilização de um conjunto de treinamento fuzzy, de forma a se ter saídas não binárias, mas que indiquem graus de pertinência nas classes “normal” e “anormal” [49]. Tal estratégia pode permitir a inclusão de informação qualitativa sobre casos fronteiros, reduzindo a quantidade de diagnósticos indeterminados e auxiliando o processo de tomada de decisão quanto à realização de ações de manutenção.

* * *

Referências Bibliográficas

- [1] Chow, Mo-Yuen. “Methodologies for Using Neural Network and Fuzzy Logic Technologies for Motor Incipient Fault Detection”, World Scientific, Singapore. 1997.
- [2] Timperley J.E., Incipient Fault Identification Through Neutral RF Monitoring of Large Rotating Machines, IEEE Trans. on Power Apparatus and Systems, Vol. 102, no.3, 1983. (R)
- [3] CIGRÈ, Problemas Mecânicos em Hidrogeradores (Relatório de Atividades), ERLAC, 2o Encontro Latino-Americano Cigré, Cigré-GT11-02, Junho, 1987;
- [4] Neale M.A., A Guide to Condition Monitoring of Machinery, London, HMSO, 1979;
- [5] EPRI, Continuous Vibration Signature Analysis - Rotating Equipment Monitoring, CS-5378, Research Project 1864-2, Setembro, 1987;
- [6] Tavner, P.J., Penman, J., Condition Monitoring of Electrical Machines, (Series: Electronic & Electrical Engineering Research Studies: Electrical Machines Series, Number 1), John Wiley & Sons Inc., 1989;
- [7] Mitchell, I. S., Introduction to Machinery Analysis and Monitoring, PennWell, 1993;
- [8] Vas, P., Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines, 1996;
- [9] Rao, J.S., Vibratory Condition Monitoring of Machines , 2000.(C)
- [10] Do Coutto, M.H.T.A., Um Sistema Especialista para o Diagnóstico Precoce de Falhas em Hidrogeradores, Dissertação de Mestrado, Depto. de Eng. Elétrica, PUC/RJ, Dezembro, 1991;
- [11] Lima, C. S., Noronha, R. F. ; Souza, J. C. S., “Manutenção Preditiva em Turbinas a Gás Aeroderivadas utilizando Redes Neurais Artificiais”, Anais do VI Simpósio Brasileiro de Automação Inteligente, 2003. v. 1. p. 325-330.
- [12] Oliveira, V.R., Jardim, J.L.A., Silva Neto, C.A., Souza, J.C.S., Schilling, M. Th., Freitas Cruz, A.A., “Avaliação em Tempo Real de Desempenho Dinâmico de Geradores Elétricos via Redes Neurais Artificiais”, XVII CBA, Juiz de Fora, MG, setembro 2008.
- [13] De Prony, Baron (Gaspard Riche), “Essai expérimental et analytique”, J. E. Polytech., Vol. 1, No. 2, pp: 24-76, 1795.

- [14] Jardim, J. L., Neto, C. S., Santos, M. G. e Gomes, P., ORGANON Um Sistema de Avaliação da Segurança Dinâmica de Sistemas de Potência, Cinter - Ciclo Interno de Debates do ONS, Rio de Janeiro, RJ, BR, Novembro de 2003.
- [15] Hauer, J. F., “Application of Prony Analysis to the Determination of Modal Content and Equivalent Models for Measured Power System Response”, IEEE Trans. on PWRs, Vol. 6, No. 3, pp: 1062-1068, August 1991.
- [16] Trudnowski, D. J., Johnson, J. M. and Hauer, J. F., “Making Prony Analysis More Accurate Using Multiple Signals”, IEEE Trans. on PS, Vol. 14, No. 1, pp: 226-231, February 1999.
- [17] Press, H.W., Flannery, P., Teukolsky, S.A., Vetterling W.T., “Numerical Recipes: The Art of Scientific Computing”, Cambridge Univ. Press, Cambridge, UK, Sec. 2.8.
- [18] Tufts, D. W, Fiore, P. D., “Simple effective estimation of frequency based on Prony’s method”, Proc. IEEE ICASSP (1996), 2801–2804.
- [19] Handel, P., Volcker, B., Goransson, B. “Analysis of simple effective frequency estimation based on Prony’s method” Proc. IEEE ICASSP (1998), 316–324.
- [20] Miller, E. K., Burke, G. J. “Using model based parameter estimation to increase the physical interpretability and numerical efficiency of computational electromagnetics”, Computer Physics Comm. 68 (1991), 43–75.
- [21] Miller, E. K., Lager, D. L. “Radiation field analysis and synthesis using Prony’s method”, Electronic Letters 14 (1978), 180–181.
- [22] Sunlap, S., Begoric, M. M.: State tracking in power systems using DFT-Prony’s method. Proc. IEEE ICASSP (1993), 2182–2186.
- [23] Jardim, J. L. A., Manual of ORGANON - User Guide, Vol. 1, Version 1.2, 2006.
- [24] Jardim, J. L. A., Manual of ORGANON - Dynamic Models Reference, Vol. 2, Version 1.2, 2006.
- [25] Jardim, J. L. A., Manual of ORGANON - Introduction Methodology, Vol. 3, Version 1.1, 2005.
- [26] Khan, M., Mackisack, M. S., Osborne, M. R. and Smyth, G. K., On the Consistency of Prony’s Method and Related Algorithms, Journal of Comput. Graph. Statistics, Vol. 1, pp: 329-349, 1992.
- [27] Braga, A., Carvalho, A., Ludemiv, T., “Redes Neurais Artificiais: Teoria e Aplicações”, LTC, Rio de Janeiro, Brasil, 2000.
- [28] McCulloch, W.S., Pitts, W., “A Logical Calculus of the Ideas Immanent in Nervous Activity”, Bulletin of Mathematical Biophysics, 5:111-133, 1943.
- [29] Hebb, D.O., “The Organization of Behavior”, Wiley, 1949.
- [30] Widrow, B., Hoff, M.E. ,“Adaptive switching circuits”, Institute of Radio Engineers, Western Electronic Show and Convention, 1960.

- [31] Roseblatt, F. “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”, *Psychol. Ver.*, 65:386-408, 1958.
- [32] Roseblatt, F., “Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms”, Spartan Books, New York, 1962.
- [33] Minsky, M., Papert, S., “Perceptrons: An Introduction to Computational Geometry”, MIT Press, Massachusetts, 1969.
- [34] Aleksander, I., “Self-adaptive Universal Logic Circuits”, *Electronic Letters*, 2:231, 1966.
- [35] Fukushima, K., “Cognitron: A Self-Organizing Multilayered Neural Network”, *Biol. Cybern.*, 23:121-134, 1975.
- [36] Grossberg, S. ,“Adaptive Pattern Classification and Universal Recording: feedback, expectation, olfaction, illusions”, *Biol. Cybern.*, 23:187-202, 1976.
- [37] Kohonen, T., “An Adaptive Associative Memory Principle”, *IEEE Transactions on Computers*, C-23: 444-445, 1974.
- [38] Hopfield, J., “Neural Networks and Physical Systems with Emergent Collective Properties”, *Proc. Nat. Acad. Sci.*, 79:2554-2558, 1982.
- [39] Rumelhart, D.E., Hinton, G.E. , Williams, R.J. ,“Learning Representations by Backpropagating Errors”, *Nature*, 323:533-536, 1986.
- [40] Werbos, P., “Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences”, PhD Thesis, Harvard University, 1974.
- [41] McCulloch, W.S., Pitts, W.. “A Logical Calculus of the Ideas Immanent in Nervous Activity”, *Bulletin of Mathematical Biophysics*, 5:111-133, 1943.
- [42] Haykin, S., “Neural Networks: A Comprehensive Foundation”, Prentice-Hall, 1994.
- [43] Hebb, D.O. , “The Organization of Behavior”, Wiley, 1949.
- [44] Linsker, R.,“Self-Organization in Perceptual Network”, *Computer*, 21(3):105-117, 1988.
- [45] Kohonen, T., “Self-Organization and Associative Memory”, Springer-Verlag, Berlin, 3rd Edition, 1989.
- [46] Carpenter, G.A., Grossberg, S., “The ART of Adaptive Pattern Recognition by a Self-Organizing Neural Network”, *Computer*, 21:77-88, 1988.
- [47] Hecht-Nielsen , R., “Kolmogorov’s mapping neural network existence theorem”, *Proc. of the Int. Conf. On Neural Networks*, IEEE Pres, Vol.3, 11-13, New York, 1987.
- [48] Cybenko , G., “Approximations by Superpositions of a Sigmoidal Function”, CSRD Report No. 856, Center for Supercomputing Research and Development, University of Illinois, February 1989.

- [49] Stacchini de Souza, J.C., Meza, E.B.M., Schilling , M.Th., Do Coutto Filho , M.B., “Alarm Processing in Electrical Power Systems through a Neuro-Fuzzy Approach”, IEEE Trans. on Power Delivery, Vol. 19, No. 2, pp. 537-544, April 2004.

* * *

Apêndice A: Escolha das Arquiteturas das Redes Neurais

das Redes Neurais

Diversos testes foram realizados, explorando várias arquiteturas para cada rede neural, de forma a definir aquelas que apresentam o melhor desempenho. A Figura A-1 até a Figura A-9 ilustram as arquiteturas testadas para o regulador de tensão (RT), para o regulador de velocidade (RV) e para o sinal adicional estabilizado (PSS), onde se pode perceber a quantidade de neurônios na camada escondida pela percentual de acertos obtidos nos casos testados.

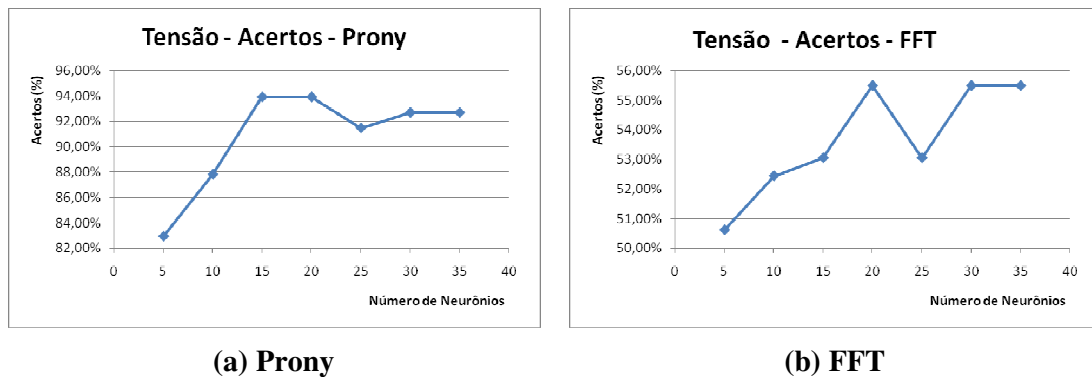


Figura A-1 Percentual de acertos da tensão terminal para o RT

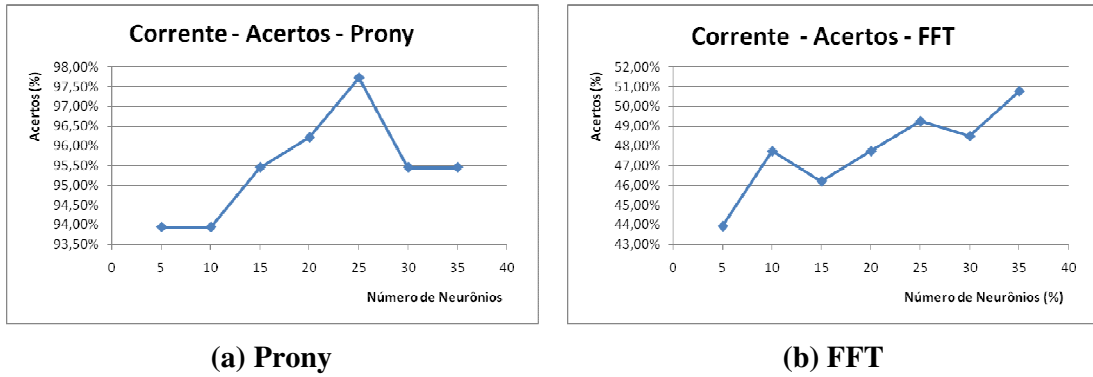


Figura A-2 Percentual de acertos da corrente da armadura para o RT

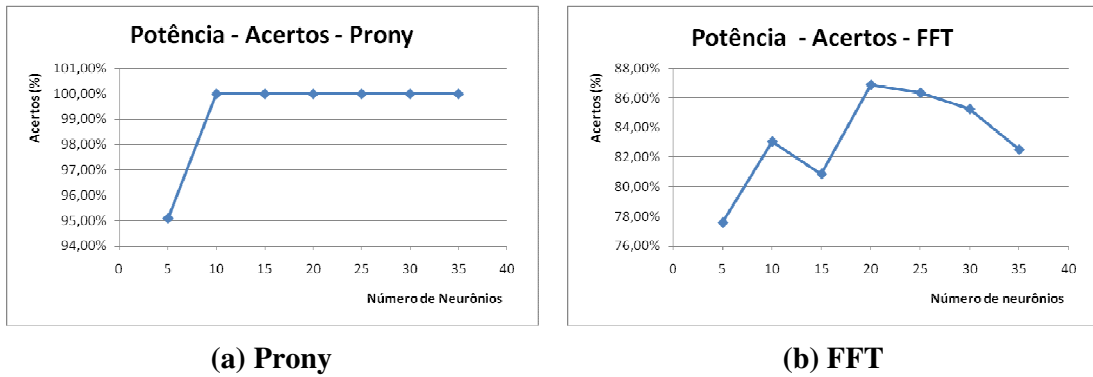


Figura A-3 Percentual de acertos da potência ativa para o RT

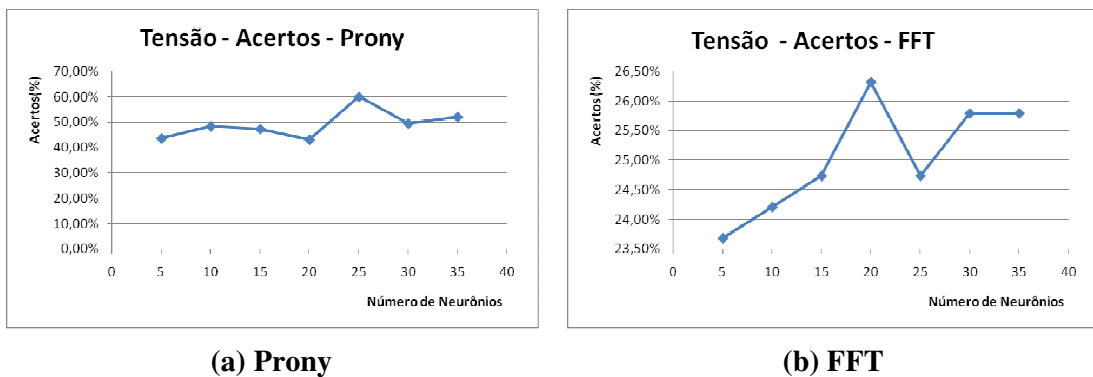


Figura A-4 Percentual de acertos da tensão terminal para o RV

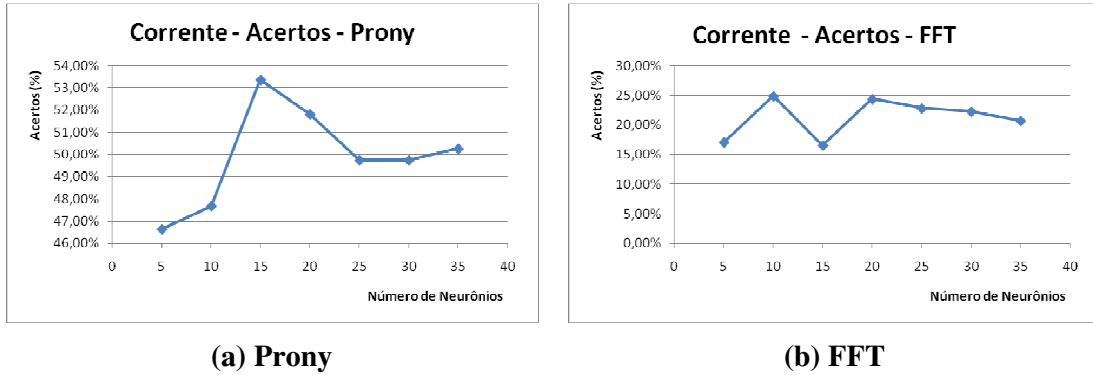


Figura A-5 Percentual de acertos da corrente da armadura para o RV

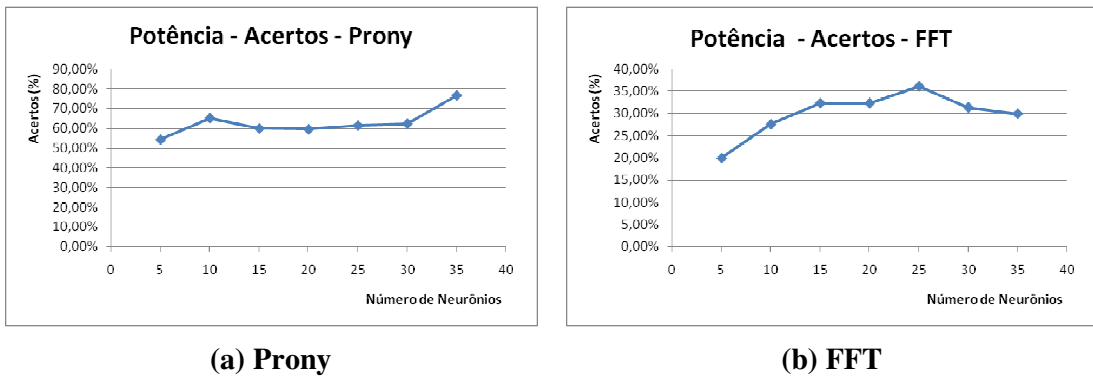


Figura A-6 Percentual de acertos da potência ativa para o RV

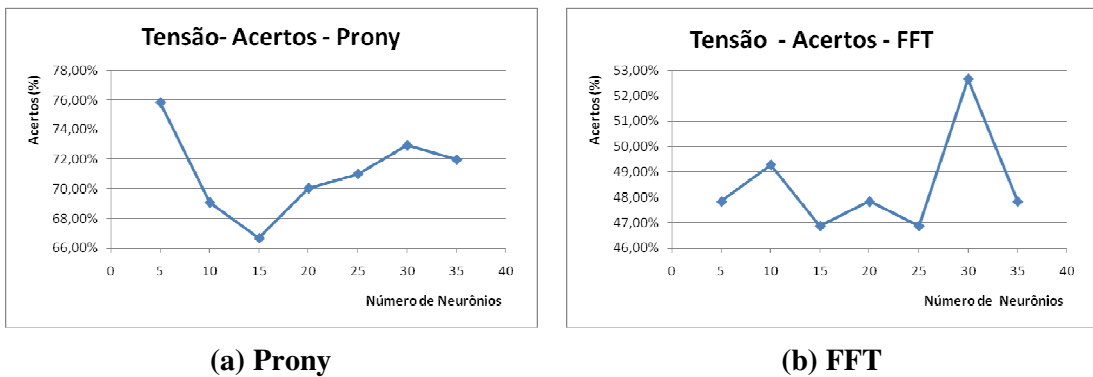


Figura A-7 Percentual de acertos da tensão terminal para o PSS

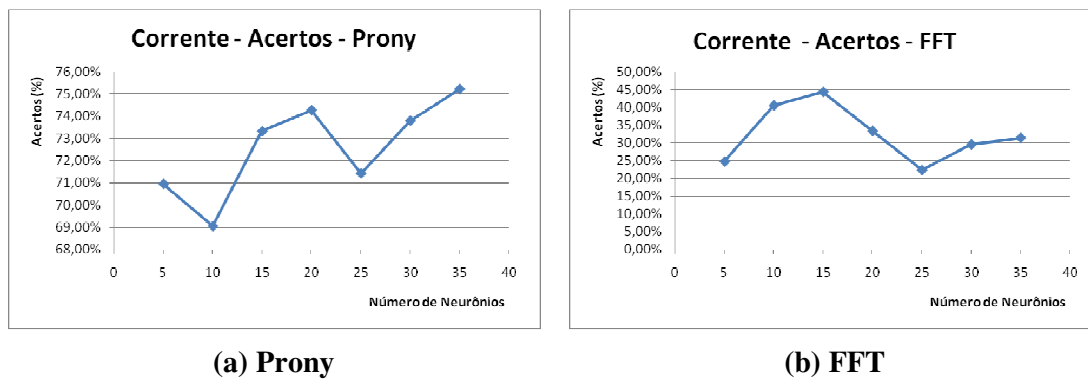


Figura A-8 Percentual de acertos da corrente da armadura para o PSS

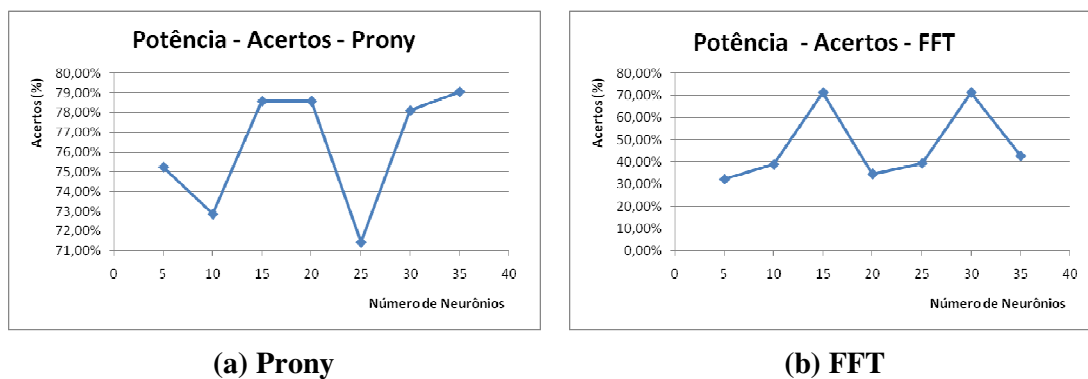


Figura A-9 Percentual de acertos da potência ativa para o PSS

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)