



**Universidade Estadual de Campinas**  
**Faculdade de Engenharia Elétrica e Computação**  
**Departamento de Sistemas de Energia Elétrica**

**Redes Neurais Artificiais Aplicadas a Sistemas de Potência**

**Autor: Heloisa Helena Müller**

**Orientador: Prof. Dr. Carlos Alberto de Castro Jr.**

**Co-Orientador: Dr. Marcos Julio Rider Flores**

Dissertação apresentada à Faculdade de Engenharia Elétrica e de Computação da UNICAMP como parte dos requisitos exigidos para obtenção do título de Mestre em Engenharia Elétrica,  
Área de Concentração: Energia Elétrica.

**Comissão Examinadora**

Prof. Dr. Carlos Alberto de Castro Junior, FEEC/UNICAMP

Prof. Dr. Ariovaldo Verândio Garcia, FEEC/UNICAMP

Prof. Dr. Denis Vinicius Coury, EESC/USP

Dra. Lia Toledo Moreira Mota, PUC/CAMPINAS

FICHA CATALOGRÁFICA ELABORADA PELA  
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

M912r Müller, Heloisa Helena  
Redes neurais artificiais aplicadas a sistemas de potência / Heloisa Helena Müller. --Campinas, SP: [s.n.], 2008.

Orientadores: Carlos Alberto de Castro Jr., Marcos Julio Rider Flores.

Dissertação (Mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Redes neurais artificiais. 2. Potência reativa (Engenharia Elétrica). 3. Otimização matemática. 4. Sistemas de energia elétrica – Controle. I. Castro Jr., Carlos Alberto de. II. Flores, Marcos Julio Rider. III. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. IV. Título.

Título em Inglês: Artificial neural networks for load flow and external equivalents studies.

Palavras-chave em Inglês: Artificial neural networks, Reactive power, Mathematical optimization, Electric power systems – Control.

Área de concentração: Energia Elétrica

Titulação: Mestre em Engenharia Elétrica

Banca examinadora: Ariovaldo Verândio Garcia, Denis Vinicius Coury e Lia Toledo Moreira Mota

Data da defesa: 12/3/2008

Programa de Pós-Graduação: Engenharia Elétrica.

## COMISSÃO JULGADORA - TESE DE MESTRADO

**Candidata:** Heloisa Helena Müller

**Data da Defesa:** 12 de março de 2008

**Título da Tese:** "Redes Neurais Artificiais Aplicadas a Sistemas de Potência"

Prof. Dr. Carlos Alberto de Castro Júnior (Presidente): \_\_\_\_\_

Prof. Dr. Denis Vinicius Coury: \_\_\_\_\_

Dra. Lia Toledo Moreira Mota: \_\_\_\_\_

Prof. Dr. Ariovaldo Verândio Garcia: \_\_\_\_\_

# Agradecimentos

Primeiramente gostaria de agradecer a Deus por colocar em meu caminho todas as pessoas e instituições que mencionarei a seguir.

- Ao Professor Carlos Alberto de Castro Jr. pela disposição em trabalhar comigo, excelente orientação, amizade e respeito, por quem tenho grande admiração.
- Ao Doutor Marcos Julio Rider Flores, pela disposição em trabalhar comigo, excelente orientação, amizade e respeito, dedicação, competência, por quem tenho grande admiração.
- À Universidade Estadual de Campinas (UNICAMP) pela sua excelência acadêmica e científica, e ao seu corpo docente por ter instrumentado-me, para meu crescimento profissional, pessoal e intelectual.
- Ao Departamento de Sistemas de Energia Elétrica (DSEE), e ao seu corpo docente e administrativo de extrema organização, eficiência, competência e inteligência.
- Aos Professores Carlos Alberto Favarin Murari, Ariovaldo Verândio Garcia, Fujio Sato, Luiz Carlos Pereira Silva, Vivaldo Fernando Costa, André Morelato França, Walmir de Freitas e Rubén Romero, pessoas admiráveis, que muito me ensinaram durante estes anos.
- Aos meus amigos do DSEE, Adriana Scheffer Quintela, Ahda P. Grillo, Marina Lavorato de Oliveira, Manfred F.B. Aronés, Madson Cortes de Almeida, Ana Carolina Garcia Canôas, Duvier R.B. Bedoya, José Carlos de Melo Vieira Júnior, Eduardo N. Asada, Hugo Murici Ayres, Igor Kopcak, Adriana L. Tognete, Marcos A.N. Guimarães.
- À Noêmia da Silva Barros Benatti, pelo seu profissionalismo e dedicação, sempre me orientando nos aspectos protocolares e administrativos.
- À FAPESP (Fundação de Amparo a Pesquisa do Estado de São Paulo) por sua colaboração e suporte.
- Às minhas Professoras de primeira a quarta série primária, respectivamente Adalgisa de Queiroz Rodero, Emília Ferrari (*in memoriam*), Neyde Theresinha Vidotti Garcia e Neusa Terêncio Simões, e a professora assistente Ivanir Francischetti, pela semente plantada em minha formação.
- Ao meu amigo Nilo Celso Ribeiro, engenheiro eletricista, um homem de visão e grande incentivador de meus estudos na área de engenharia.

- Ao Srs. José Ricardo Portillo Navas e Carlos Alberto Fróes Lima pelo apoio e suporte recebido através da empresa KNBS Telecomunicações e Informática LTDA (Knowledge Networks and Business Solutions).
- As minhas queridas irmãs Eneida Helena Müller Marques Troncoso e Cristina Helena Müller, pelo apoio e suporte dado à minha educação durante a minha infância e adolescência.

Dedico este trabalho  
À minha mãe, Lucila;  
Ao meu pai, Walter;  
À minha bisavó Dona Ana (*in memoriam*);  
À minha amiga Glória Souza de Almeida.

# Resumo

A operação de um sistema de energia elétrica pode ser gerenciada remotamente através dos centros de controle utilizando sistemas de gerenciamento de energia (*Energy Management Systems-EMS*). Nesses centros de controle são realizadas e executadas freqüentemente muitas funções em tempo real e em modo de estudo. Dentre estas funções têm-se: o controle automático da geração, a estimação de estado, análise de topologia e análise estática de segurança entre tantas outras. A base da resolução destas funções é a execução e testes de um grande número de cálculos de fluxos de potência. A estimativa de estado de um sistema de potência pode ser determinada resolvendo as equações de um fluxo de carga, que matematicamente são representadas por um conjunto de equações algébricas não lineares. Este problema é conhecido como fluxo de potência ou fluxo de carga, e o seu objetivo principal é o cálculo das magnitudes das tensões e seus ângulos de fase, e conseqüentemente dos fluxos de potência nas linhas de transmissão.

O objetivo deste estudo é usar redes neurais artificiais (RNA) na: **(a)** solução do fluxo de carga (FC); **(b)** solução do FC considerando controle de limites de tensão nas barras PV; **(c)** inicialização de um FC para sistema mal condicionados; e **(d)** cálculo de equivalentes externos estáticos para sistemas de energia elétrica.

A idéia é que um fluxo de potência baseado em RNA seja mais rápido que o fluxo de potência convencional baseado no método de Newton-Raphson, particularmente nos casos envolvendo aplicações em tempo real e em modo de estudo avançadas de fluxos de potência no EMS.

# Abstract

The operation of electric power systems can be managed remote and automatically from control centers using energy management systems (EMS). In these control centers many on-line and off-line functions are carried out periodically. Among those functions, we can list: the automatic generation control, state estimation, topological analysis, and static security analysis. These functions are based on the calculation of a large number of power flows. The operating state of power systems may be determined by solving power flow equations that are mathematically represented by a set of non-linear algebraic equations. This problem is known as the load flow or power flow problem and its main objective is the calculation of all bus voltage magnitudes and angles, and consequently the power flows through the transmission lines. The goal of this study is to propose an artificial neural networks (ANN) based methodology for **(a)** solving the basic load flow, **(b)** solving basic load flow considering reactive power limits of generation (PV) buses, **(c)** determining a good quality load flow starting point for ill-conditioned systems, and **(d)** computing static external equivalent circuits. The proposed ANN based power flow solver is intended to be faster than the conventional power flow problem solvers which use Newton-Raphson method, particularly in those cases involving advanced on-line applications of the power flow problem in the EMS.



# Sumário

Capítulo 1 .....	1
Introdução.....	1
1.1    Histórico Bibliográfico.....	3
Capítulo 2 .....	7
Redes Neurais Artificiais .....	7
2.1    Modelo Humano e sua Biologia.....	8
2.2    Modelo Matemático Genérico.....	10
2.3    Arquiteturas de RNA.....	13
2.4    Aprendizado da RNA .....	15
2.4.1 Tipos de Aprendizado .....	15
2.4.2 Tarefas do Aprendizado .....	16
2.5    Algoritmos de Treinamento .....	17
2.6    Pré e Pós Processamento de Informações .....	18
2.7    RNA e Arquitetura Adotada no Projeto .....	19
Capítulo 3 .....	27
3.1    Contingências .....	28
3.2    Fluxo de Carga sem Consideração de Controles e Limites.....	28
3.3    RNA e Fluxo de Carga sem Controles e Limites .....	30
3.4    Metodologia Utilizada no Treinamento das RNAs .....	32
3.5    FC com RNA (FC-RNA) .....	36
3.6    Testes Realizados FC-RNA .....	37
3.7    Fluxo de Carga com Controles e Limites.....	41
3.8    FC com Controle de Limites e RNA (FC-RNA-CTRL).....	43
3.9    Testes Realizados FC-RNA-CTRL.....	46
Capítulo 4 .....	53
Inicialização de FC com RNA .....	53
4.1    Fluxo de Carga com Passo Ótimo.....	54
4.2    Fluxo de Carga CPO e RNA (FC-RNA-CPO).....	55
4.3    Fluxo de Carga Inicializado por RNA.....	56
4.4    Testes Realizados para o Sistema de 11 barras .....	57
4.5    Testes Realizados para o Sistema IEEE057 .....	63
Capítulo 5 .....	65
Equivalentes Externos .....	65
5.1    Equivalentes usando RNA .....	66
5.2    Testes Realizados para o Sistema IEEE030.....	68
5.3    Testes Adicionais Realizados para o Sistema IEEE030.....	70
5.4    Testes Realizados para o Sistema IEEE057 .....	72
Capítulo 6 .....	83
Conclusões .....	83
Apêndice I .....	87
Tipos de Controles e Limites .....	87
Transformadores em Fase e Controle Automático de Tap.....	88
Transformadores Defasadores com Controle Automático de Fase.....	89

Controle de Intercâmbio entre Áreas .....	90
Controle de Tensão em Barras Remotas .....	91
Apêndice II – Arquivos dos Sistemas .....	93
WARD-HALE 6 BARRAS.....	93
Sistema 11 Barras.....	94
IEEE 14 BARRAS .....	96
IEEE 30 BARRAS .....	98
IEEE 57 BARRAS .....	100
Referências Bibliográficas .....	103
Trabalhos afins publicados pela autora .....	107

# Capítulo 1

## Introdução

A operação de uma rede de energia elétrica pode ser gerenciada remotamente através dos centros de controle utilizando sistemas de gerenciamento de energia. Nestes centros de controle são executadas periodicamente funções de análise em tempo real e em modo de estudo. Dentre estas funções pode-se mencionar o controle automático da geração, a estimação de estado, a análise topológica e a análise de segurança estática. A base da resolução da maioria das funções mencionadas é a execução e cálculo de um grande número de fluxos de carga (FC) [1,2].

O objetivo principal do cálculo de FC é determinar o estado de operação em regime permanente do sistema elétrico [1], obtendo as magnitudes das tensões e os ângulos de fase em todas as barras, e conseqüentemente, outras grandezas derivadas destas, como fluxos de potência ativa e reativa nas linhas, potências reativas dos geradores, perdas de potência ativa e reativa, entre outras.

A maioria dos FCs são resolvidos utilizando o método iterativo de Newton-Raphson (NR) ou suas versões desacopladas XB e BX [1,2]. Geralmente, obtém-se o estado de operação da rede após algumas poucas iterações, para a maioria dos casos. No entanto, existem situações correspondentes a casos críticos, como para sistemas mal condicionados, em que há a necessidade de utilização de técnicas complementares, como por exemplo, o multiplicador de passo ótimo [3]. Há ainda situações em que não há solução ou convergência do processo iterativo para o FC.

Para ilustrar um pouco mais o grau de complexidade da análise de sistemas elétricos, uma das tarefas que consome mais recursos de processamento é a seleção e análise de contingências, onde é essencial o cálculo do estado da rede determinada pelo FC em poucos minutos, considerando o conjunto de contingências e as diferentes condições de demanda. Esforços têm sido realizados para melhorar o desempenho do FC, como a aplicação de técnicas de exploração

da esparsidade de matrizes, processamento paralelo, etc. Mas para sistemas de grande porte é difícil resolver todos os casos de FC em um intervalo de tempo pequeno requerido pelo centro de controle na operação em tempo real [4], mesmo com os recursos computacionais atuais.

Recentemente, várias técnicas alternativas de inteligência artificial (IA) têm sido desenvolvidas e aplicadas com sucesso nas diversas áreas da engenharia. Na área de sistemas de potência têm sido adotados sistemas especialistas e sistemas baseados no conhecimento para realizar funções avançadas de análise nos centros de controle, tanto em tempo real como em modo off-line. Uma das técnicas IA é a rede neural artificial (RNA), que tem sido utilizada com sucesso na área de reconhecimento de padrões, tarefas de classificação e tarefas de predição [5].

O *perceptron* multicamada (MLP - *multilayer perceptron*) é a arquitetura de rede neural mais utilizada na engenharia, inclusive para aplicações em sistemas de potência [4], e será adotada neste trabalho. Sua estrutura básica é mostrada na Figura 1.1. Considera-se que as RNA-MLP são capazes de resolver problemas complexos com grau de dificuldade relativo similar ou superior ao problema da não linearidade do FC. Neste trabalho, a RNA foi treinada utilizando o método de segunda ordem Levenberg-Marquardt.

Neste trabalho, o objetivo é utilizar a RNA para: **(a)** resolver o problema de FC convencional; **(b)** resolver o problema de FC considerando e limites de tensão nas barras de geração (PV); **(c)** iniciar um FC para sistemas mal condicionados; e **(d)** calcular equivalentes externos estáticos. A metodologia foi testada usando os sistemas de teste Ward-Hale de 6 barras, IEEE de 14, 30 e 57 barras [6], considerando condições normais de operação (caso base) e diversos casos de contingências incluindo diferentes cenários de carga e geração.

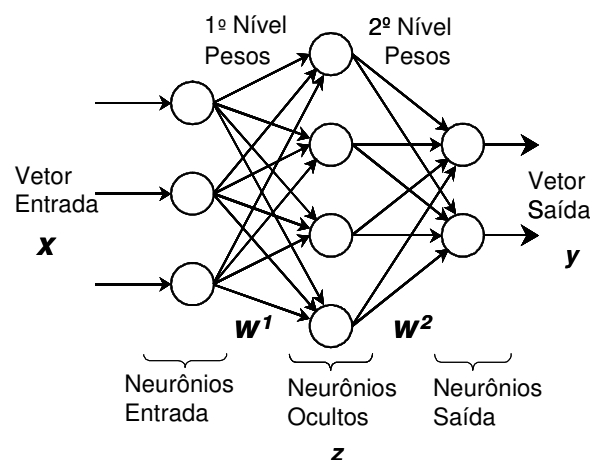


Figura 1.1: Diagrama esquemático da rede MLP.

A idéia da utilização das RNA é obter um ganho de tempo computacional nas aplicações dos itens **(a)-(d)** frequentemente utilizadas em tempo real nos centros de controle. Esta idéia é possível considerando que o processo de treinamento pode ser realizado off-line e os parâmetros das RNA podem ser armazenados. Para os eventos em tempo real somente utiliza-se a RNA para obter resultados utilizando simulações simples, e além disto, as RNA não apresentam problemas de convergência depois de treinadas adequadamente.

Outro aspecto é considerar o FC-RNA como uma alternativa aos métodos numéricos convencionais, e trabalhar o controle de limites de geração das barras PVs aplicados ao FC-RNA, considerando que não foram encontradas referências sobre este assunto na literatura de aplicações de fluxo de carga e RNA.

Nos capítulos 2, 3, 4, 5 e 6 serão descritas as metodologias e técnicas usadas para implementar as proposições utilizando as RNA, suas respectivas arquiteturas, métodos de treinamento, montagem da base de conhecimento, dificuldades encontradas, e finalmente as conclusões, onde serão feitas considerações sobre o trabalho e serão apresentadas algumas idéias para trabalhos futuros.

## **1.1 Histórico Bibliográfico**

Os trabalhos foram iniciados no ano de 2005. Foram encontradas poucas referências relacionadas aos assuntos propostos no trabalho. Estão relacionados nas referências bibliográficas, vários autores que possuíam artigos referentes ao tema.

Do ano de 1989, tem-se o artigo de Dejan J. Sobajic e Yoh-Han Pau [7], que tratava de um método para análise dinâmica das contingências em um sistema de potência, considerando o tempo de recuperação da falha (CCT) como um dos parâmetros de maior importância, que é definido por funções de pré-análise das condições das falhas, como tipo, localização e estratégia de proteção. O cálculo do tempo de recuperação requer a execução de muitos programas com equações matemáticas não lineares, que demanda um consumo alto de tempo. O trabalho propôs a utilização de uma abordagem para reconhecimento de padrões, baseado no alto processamento paralelo de informações usando redes neurais artificiais.

Do ano de 1992, tem-se o artigo de R. Battiti [8], onde eram apresentados métodos de treinamento de RNAs de primeira e segunda ordem e apresentação do método de ajuste de passos e o método de Newton. Ainda do ano de 1992, tem-se o artigo de H. Mori, cálculo de um loadflow usando um modelo de rede neural artificial de Hopfield [9].

Do ano de 1995, tem-se o artigo de Martin Hagan e Mohammad B. Menhaj [10], que apresentava a eficiência do algoritmo de treinamento de RNA de Marquardt para redes com algumas centenas de pesos sinápticos. Ainda de 1995, tem-se o artigo de T. T. Nguyen [11], que apresentava uma arquitetura de redes neurais artificiais para resolver cada etapa envolvida representada pelas equações de um fluxo de carga Newton-Raphson, e as análises voltadas para os benefícios apresentados na resolução.

Do ano de 1996, tem-se o artigo de M. El-Sharkawi e D. Niebur [4], que apresentava redes neurais artificiais com aplicações para sistemas de potência.

Do ano de 1998, tem-se o artigo de Michael J. Cooke e Gary L. Leiby [12], que apresentava uma arquitetura de redes neurais artificiais baseadas nos método *backpropagation learning algorithm* para resolver um fluxo de carga, e a comparação de desempenho entre a RNA e o método Newton-Raphson. Ainda de 1998, tem-se o artigo de K. L. Lo, L. J. Peng, J. F. Macqueen, A. O. Ekwue, e D. T. Y. Cheng [13], que apresentava um método rápido para classificação de contingências em tempo real utilizando o modelo de RNA *Counter-propagation*.

Do ano de 1999, tem-se o artigo de J. A. Refaee, M. Mohandes e H. Maghrabi [14], que apresentava uma arquitetura de redes neurais artificiais radiais para classificação de contingências em sistemas de energia grandes e complexos. Ainda de 1999, tem-se o artigo de T. S. Chung e Fu Ying [15], que propunha a utilização de RNA para o cálculo do equivalente *on-line* considerando as medições das magnitudes de tensões de ângulos de fase das barras de fronteira como entrada para o treinamento das RNA, e saída o cálculo das injeções de potência ativa e reativa nas barras de fronteira. Foi testado para um sistema de 39 barras, e o comentário dos autores que é necessário reunir o maior número de medidas e casos variados para obter um bom desempenho da RNA.

Do ano de 2000, tem-se o artigo de V. Leonardo Paucar e Marcos J. Rider [16], onde foi proposto um método de inicialização para fluxo de carga Newton-Raphson por uma RNA com perceptrons de múltiplas camadas que calculava a magnitude das tensões e ângulos de fase. O método foi testado no sistema Ward-Hale de 6 barras, e sistema IEEE 14 barras, e apresenta

conceitos de utilização da diagonal da matriz de admitância nodal composta com valores da potência de geração, tensão das barras de geração e injeções de potência ativa e reativa, como entrada da rede. Este artigo é considerado uma importante referência para o trabalho.

Do ano de 2002, tem-se o artigo de V. Leonardo Paucar e Marcos J. Rider [17], onde foi proposto um método de cálculo de fluxo de carga Newton-Raphson por um conjunto de RNA com perceptrons de múltiplas camadas, treinadas pelo algoritmo de Levenberg-Marquardt que calculava a magnitude das tensões e ângulos de fase separadamente com dimensão de NPQ e NPQ+NPV, onde NPQ corresponde ao número de barras PQ e NPV corresponde ao número de barras PV. O método foi testado no sistema IEEE 30 barras, e apresenta também conceitos de utilização da diagonal da matriz de admitância nodal composta com valores da potência de geração, tensão das barras de geração, e injeções de potência ativa e reativa, como entrada da rede. Este artigo é considerado uma importante referência para o trabalho, e a partir dele foram desenvolvidas outras técnicas de utilização.

No ano de 2003, tem-se o artigo de Aleksandar M. Stancovic, Andrija T. Saric e Mirjana Milosevic [18], para a identificação de equivalentes dinâmicos não parametrizados com redes neurais artificiais.

No ano de 2004, tem-se o artigo de A. M. Azmy, I. Erlich e P. Sowa [19], que tratou de equivalentes dinâmicos com redes neurais artificiais para sistemas com fontes ativas.

No ano de 2005, tem-se o artigo de V. Muller e D. Nelles, com a utilização de redes neurais artificiais com modelos radiais e lógica *fuzzy* para cálculo de equivalentes estáticos. Este equivalente propôs duas técnicas: utilização dos valores das potências ativa e reativa como entrada para calcular as tensões e a diferença entre os ângulos das barras de fronteira com a utilização de um ângulo igual a zero na entrada; utilização da medida de tensão da primeira barra interna e as potências de transmissão de todas as barras internas como entrada. Foi realizado um teste em uma rede de 220 kV, mas não foi apresentada a topologia da rede.

No ano de 2005, foi publicado o primeiro trabalho referente a esta tese, corresponde ao artigo de H. H. Müller, Marcos Julio Rider, Carlos Alberto Castro Jr. e Vicente Leonardo Casa Paucar [21], modelo de fluxo de carga usando redes neurais artificiais, onde foram tratadas, em adição à publicação de 2002, a inclusão de novas técnicas de treinamento, revisão dos parâmetros de normalização, inclusão de outras contingências, testes com os sistemas Ward-Hale 6 barras, IEEE 14 barras e IEEE30 barras com a apresentação de erros absolutos menores, dos que os

obtidos em 2002. Ainda no ano de 2005, foi publicado o segundo trabalho referente a esta tese, corresponde ao artigo de Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr., V. L. Paucar [22], modelo de fluxo de carga usando redes neurais artificiais, onde foram acrescentados ao trabalho realizado pelo artigo anterior [16], a rede IEEE 57 barras e aperfeiçoamento de novas técnicas de treinamento e revisão das dimensões das RNA, e a menção dos trabalhos que estavam sendo realizados para a parte de equivalentes de rede.

Foi considerada uma existência restrita de artigos relacionados diretamente a este trabalho. Na literatura foram encontrados testes com sistemas pequenos, não foram encontradas referências a controle de limites e também de inicialização de fluxo de carga mal condicionados, e a referência ao cálculo de equivalentes embora em quantidade maior, explorava técnicas diversas das apresentadas por este trabalho.



## Capítulo 2

### Redes Neurais Artificiais

As pesquisas com redes neurais artificiais (RNA) têm sido principalmente motivadas pela reflexão de que o cérebro humano processa as informações diferentemente de um computador convencional. Fazendo-se uma analogia pode-se dizer que o cérebro é um computador complexo, não linear e paralelo. O cérebro possui a capacidade de se organizar de forma estrutural, através dos neurônios, de modo a realizar rapidamente certas operações como reconhecimento de padrões, percepção e controle motor, passando assim por todos os sentidos de um ser humano, e as suas combinações. O cérebro humano possui características marcantes como aprendizado e armazenamento de informações de forma constante, e está sempre em processo de adaptação [5].

A RNA empresta do cérebro sua estrutura e conceito para ser uma alternativa ao processamento de informações, considerando que seu conhecimento é adquirido através de um processo de aprendizagem e treinamento, e o conhecimento adquirido é armazenado nos pesos sinápticos, que fazem a ligação entre os neurônios artificiais. O treinamento de uma RNA interfere e modifica os pesos sinápticos de acordo com um objetivo a ser atingido.

A riqueza da utilização das RNA está na sua característica de generalização, ou seja, a RNA pode produzir saídas, a partir de informações de entrada que não foram usadas previamente no seu treinamento.

Uma das fortes características das RNA é sua não linearidade, o que a torna interessante para processar informações não lineares também. O seu mapeamento de entrada e saída confere à mesma o perfil de aprendizagem e tratamento de padrões a serem submetidos aos seus algoritmos matemáticos e computacionais de treinamento. Considera-se a RNA adaptável, sendo possível alterar dinamicamente seus pesos sinápticos, e pode-se implementar em suas análises a validação de suas saídas contra evidências e assim melhorar seu desempenho na precisão das respostas aos problemas aos quais será submetida.

A RNA possui interligação completa entre seus neurônios, sendo que este conjunto é afetado de forma contextual e não tratado individualmente. A RNA é tolerante a falhas e possui uma robustez maior sobre condições de operação adversas, e na sua definição está naturalmente embutido o conceito de paralelismo tão importante na computação convencional. Na parte organizacional existem padrões de nomenclatura e representação das RNA que facilitam o seu entendimento e seu projeto [5].

Todavia, isoladamente elas têm pouco valor, necessitando serem acopladas a outros sistemas para receberem entradas de informações para executar sua tarefa de aprendizado e depois serem utilizadas com objetivos definidos. Atuam assim, de forma complementar aos sistemas computacionais convencionais.

## 2.1 Modelo Humano e sua Biologia

O cérebro humano é composto basicamente por células chamadas neurônios. No cérebro humano existe uma quantidade significativa destas células, aproximadamente mais de 10 bilhões de neurônios, e 60 trilhões de conexões [5]. A área do cérebro onde se alojam estes neurônios é conhecida por córtex.

O cérebro interage bidirecionalmente com o meio externo através do binômio estímulo e resposta, conforme mostra a Figura 2.1. Esta interação dá-se através de impulsos elétricos para recepção e transmissão de informações.



Figura 2.1: Representação em diagrama de blocos do sistema nervoso

O conjunto de neurônios se interliga e comunica-se através de sinapses cerebrais, que geralmente são consideradas químicas, pois convertem um sinal elétrico pré-sináptico em um sinal químico pós-sináptico. Esta é uma estrutura de comunicação muito poderosa e complexa que confere ao cérebro a possibilidade de recepção, ação, aprendizado e regeneração. As sinapses podem dar-se através da criação de novas conexões e da modificação de conexões já existentes.

A estrutura genérica de um neurônio é composta basicamente por três importantes itens: dendritos, corpo celular e axônio, conforme mostra a Figura 2.2 [23].

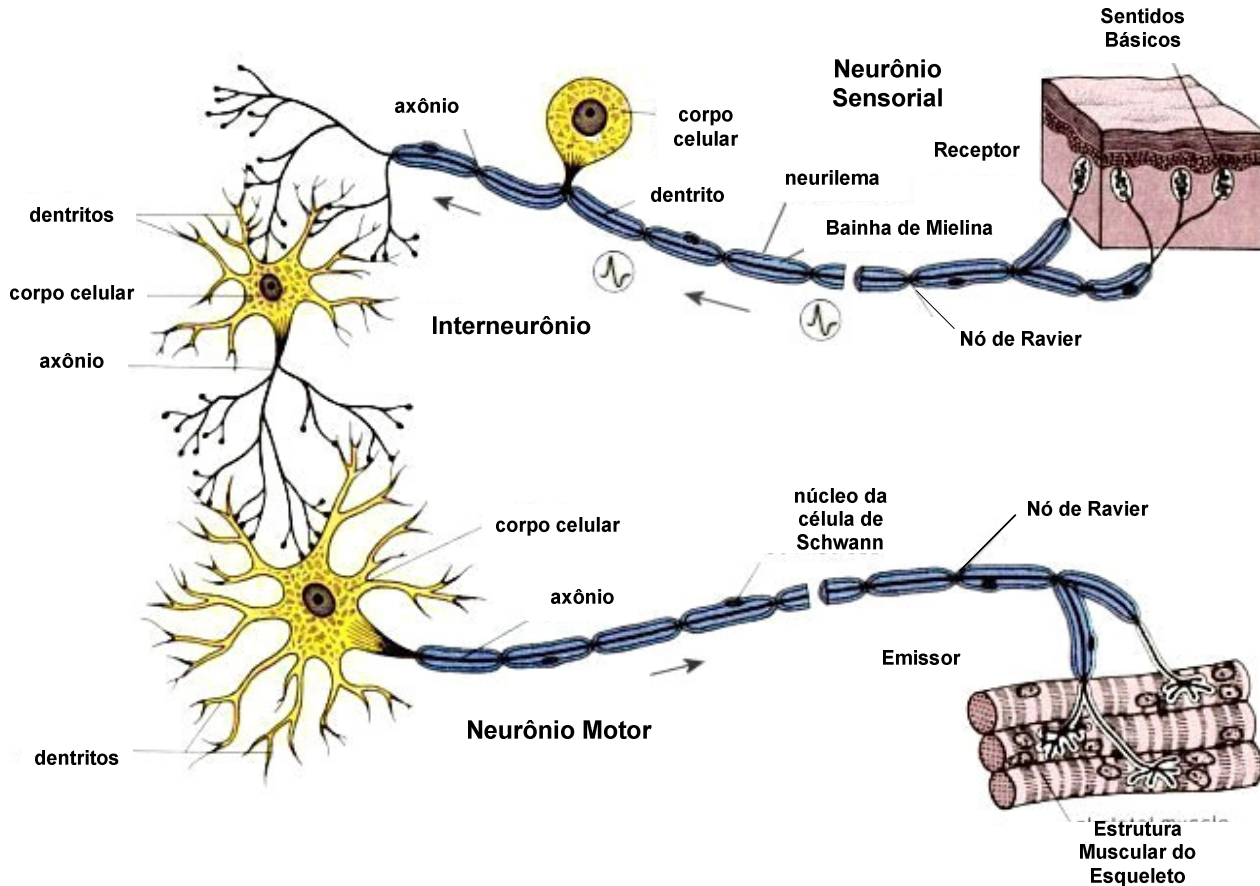


Figura 2.2: Célula Piramidal

Os dendritos são responsáveis pela parte de processamento e integração das correntes de um neurônio, e assemelha-se a uma árvore cheia de terminais receptores, o corpo celular trata os sinais recebidos pelos dendritos, e de acordo com o nível de excitação transmitirá as respostas através do axônio. O axônio funciona como se fosse uma linha de transmissão RC de alta resistência elétrica e grande capacitância, e é responsável pela transmissão de um sinal para os próximos neurônios candidatos a conexão ou sinapse na cadeia neuronal do cérebro [5].

Sobre os aspectos biológicos da estrutura e funcionamento cerebral, o neuropsicólogo Donald O. Hebb postulou a seguinte regra conhecida como A lei de Hebb [5]: *“Quando um axônio da célula A está perto o suficiente para excitar uma célula B e participa do seu disparo repetida ou persistentemente, então algum processo de crescimento ou modificação metabólica acontece em uma das células ou em ambas, de tal forma que a eficiência de A, como uma das células que dispara B, é aumentada”*.

Um outro conceito muito importante que foi introduzido por McCulloch, psiquiatra e neuroanatomista, e pelo matemático Pitts em 1943, é a lei do tudo ou nada do cérebro. No trabalho os autores unificaram os estudos da neurofisiologia e da lógica matemática, definindo que uma rede de unidades neuronais conectada através de sinapses ajustadas apropriadamente e operando de forma síncrona, realizaria, a princípio, a computação de qualquer função computável [5].

Estes postulados sobre aprendizado, e a estrutura cerebral, são muito importantes para o entendimento da aplicação das RNA na solução de problemas, ressaltando que o modelo artificial é apenas uma visão simplificada do modelo cerebral.

Os trabalhos destes cientistas influenciaram sobremaneira muitas pesquisas nas áreas de redes neurais e inteligência artificial [5], e de acordo com relatórios da agência DARPA (*Defense Advanced Research Projects Agency*) de 1988, as redes neurais artificiais estão presentes em aplicações aeroespaciais, automotivas, financeiras, bancárias, de defesa e proteção, eletrônica, entretenimento, industriais, seguros, manufatura, médicas, prospecção de recursos naturais, robótica, reconhecimento de voz, segurança, telecomunicações, transportes e logística.

## 2.2 Modelo Matemático Genérico

Um neurônio é a unidade básica de operação de uma rede neural. Assim como no cérebro, o neurônio virtual também possui uma representação, dada pela Figura 2.3, que é a base para o projeto de RNA.

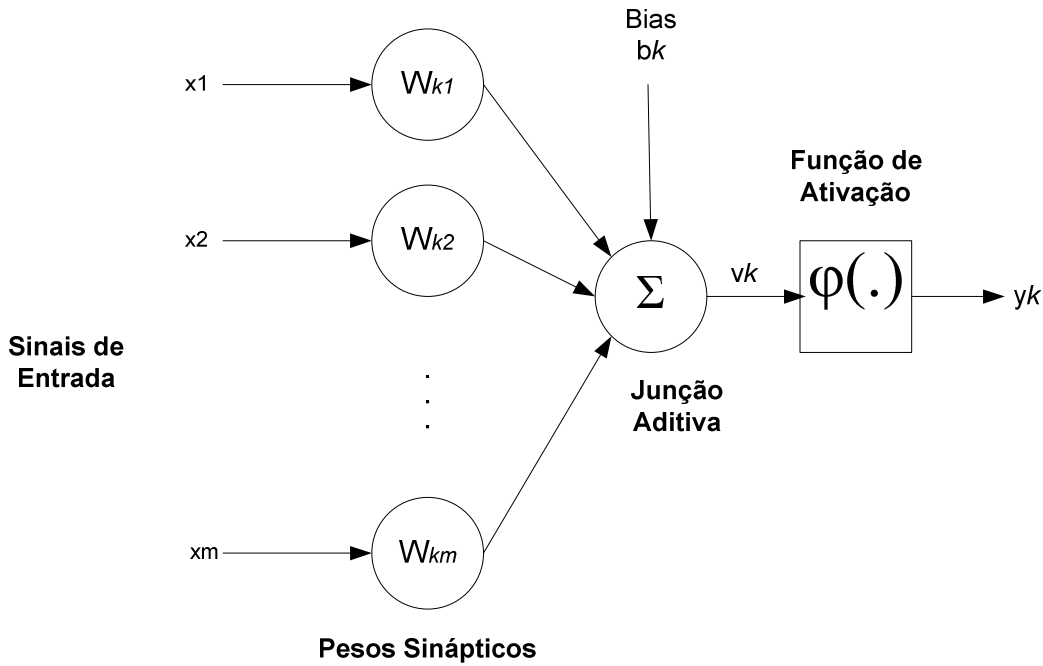


Figura 2.3: Modelo não-linear de um neurônio

Um conjunto de sinapses ou elos de conexão é representado pelas entradas  $x_j$ , da sinapse  $j$  conectadas ao neurônio  $k$ , cada qual com seus valores, e estes valores são multiplicados pelo peso sináptico  $w_{kj}$ . Um somador existe para somar os sinais de entrada ponderados pelas respectivas sinapses do neurônio, e a função de ativação para delimitar a amplitude da saída do neurônio, onde o intervalo poderá ser  $[0,1]$  ou  $[-1,1]$ .

O outro elemento é o *bias*, utilizado para aumentar ou diminuir a entrada líquida da função de ativação, dependendo de seu valor ser positivo ou negativo.

O equacionamento matemático resultante da representação do neurônio é:

$$\mu_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

$$v_k = (\mu_k + b_k) \quad (2.2)$$

$$y_k = \varphi(v_k) \quad (2.3)$$

A função de ativação representada por  $\varphi(\cdot)$ , que define a saída do neurônio, possui diferentes representações que podem ser usadas de acordo com a necessidade e projeto a ser implementado. As funções mais comuns são mostradas na Figura 2.4.

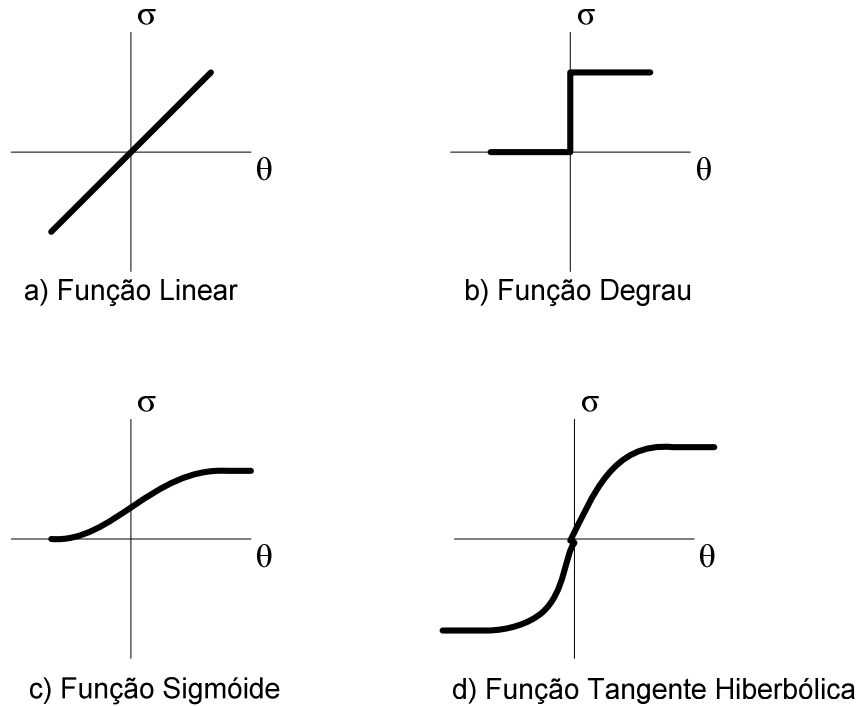


Figura 2.4: Funções de Ativação

Estas funções correspondem respectivamente às seguintes formulações:

$$a) \quad \sigma(\theta) = \theta \quad (2.4)$$

$$b) \quad \sigma(\theta) = \begin{cases} 1 & \theta \geq 0 \\ 0 & \theta < 0 \end{cases} \quad (2.5)$$

$$c) \quad \sigma(\theta) = \frac{1}{1 + e^{-\theta}} \quad (2.6)$$

$$d) \quad \sigma(\theta) = \text{tgh}(\theta) \quad (2.7)$$

Estas formulações não consideram as complexidades de um neurônio biológico, sua dinâmica e sincronismo, mas são suficientes para representar as capacidades inerentes ao neurônio biológico relativas ao processo de aprendizagem e generalização.

### 2.3 Arquiteturas de RNA

Considere que dois ou mais neurônios possam ser combinados em uma camada, e que uma rede pode possuir um ou mais camadas. A arquitetura estrutural da RNA poderia ser definida em RNA camada única conforme Figura 2.5 e redes multicamadas conforme Figura 2.6 [5].




Figura 2.5: RNA de camada única




Figura. 2.6: RNA multicamada

As RNA de camada única possuem uma camada de entrada ligada diretamente com a camada de neurônios que processam os sinais e despacham as respostas para a camada de saída. Na RNA multicamada, tem-se a camada de entrada, um número de camadas intermediárias e por fim a camada de saída.

Com relação à modelagem das entradas, estas RNA podem ser consideradas não recorrentes, pois as saídas não realimentam a camada de entrada. Estas RNA são chamadas de redes *perceptrons* e *perceptrons* multicamadas.

As RNA recorrentes são aquelas em que as saídas realimentam a camada de entrada conforme Figura 2.7. Os modelos mais comuns de redes recorrentes são o de Elman e o de Hopfield [5].

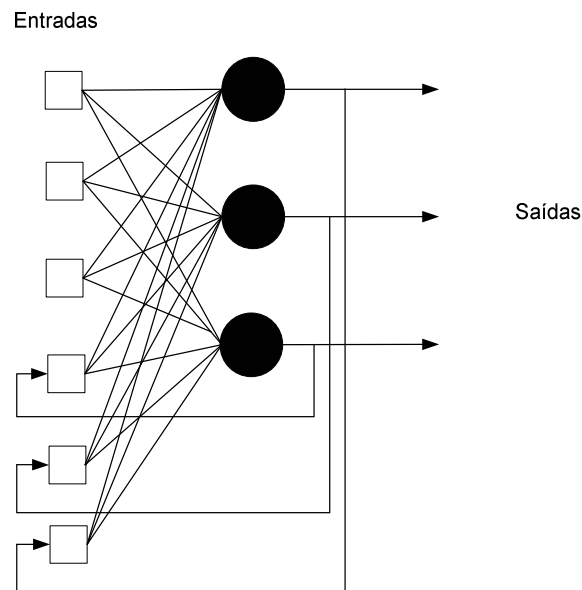


Figura 2.7: RNA recorrente

Considerando os aspectos relativos ao modelo de neurônio, as funções de ativação, a estrutura da RNA, e os aspectos de recorrência, podem-se montar vários tipos de arquiteturas de RNA.



## 2.4 Aprendizado da RNA

A consideração mais importante sobre as RNA é a sua capacidade de aprendizado. A aprendizagem é um processo iterativo onde são aplicados ajustes aos pesos sinápticos e ao bias. Pode-se considerar que a rede torna-se mais instruída e informada a cada iteração no seu processo de aprendizagem [5].

Os conceitos de aprendizagem do ponto de vista biológico são muito amplos e polêmicos e não há consenso sobre este assunto. Da mesma forma também, não existe um único algoritmo para representar o processo de aprendizado, e sobre este paradigma, e sobre os métodos existentes, podem surgir, a cada dia, novos algoritmos de aprendizagem.

As atividades iniciais de um projeto em RNA devem considerar o domínio e conhecimento do problema a ser tratado, e é necessário possuir informações prévias e dados do problema, para que seja possível modelá-lo e resolvê-lo usando RNA. Esta tarefa de levantamento e investigação da existência de informações e qual a sua veracidade é muito importante em um projeto. Sem estas premissas fica muito difícil a construção de modelo de soluções baseadas em RNA.

O processo de aprendizagem possui algumas regras básicas que serão apresentadas no intuito de explorar suas características. Nesse contexto, tem-se a aprendizagem por correção de erros, baseada em memória, Hebbiana, competitiva, e de Boltzmann [5].

Considerando a arquitetura de RNA adotada no projeto pode-se dizer que o algoritmo de Levenberg Marguardt utiliza-se de aprendizagem por métodos de correção de erros.

### 2.4.1 Tipos de Aprendizado

Os tipos de aprendizado podem ser divididos em aprendizado com supervisão e sem supervisão.

Na aprendizagem supervisionada, parte-se de um conhecimento prévio representado pelos exemplos de entradas e saídas, e a ignorância inicial da rede neural em relação a estes padrões. Assim, quando se submete este exemplo à RNA ela reage aplicando correções aos pesos sinápticos, e cabe ao processo de aprendizado supervisionado conduzir o erro representado pela diferença entre a saída obtida e a saída esperada aos valores mínimos estipulados pelo processo

de supervisão. Os erros pertencem à superfície do espaço de solução do erro podendo ser um mínimo local ou global. Esta busca tem caráter aleatório.

Na aprendizagem não supervisionada não existe o conhecimento prévio para ser aplicado e controlado. Sob esta óptica, tem-se a aprendizagem por reforço, e a aprendizagem auto-organizada. Na primeira, o mapeamento das entradas e saídas é realimentado continuamente através da interação com o ambiente visando a melhoria do desempenho. Na segunda, a rede funciona como se fosse autodidata e trabalha sobre a possibilidade de poder aprender e libera seus parâmetros confiando nesta possibilidade. Realiza isto se ajustando às regularidades estatísticas dos dados de entrada, criando novas classes e padrões automaticamente [5].

Considerando a arquitetura de RNA adotada no projeto, pode-se dizer que o algoritmo de Levenberg-Marguardt utiliza-se de técnicas de aprendizagem supervisionada.

## 2.4.2 Tarefas do Aprendizado

As tarefas de aprendizagem que se aplicam às RNA são divididas em associação de padrões, reconhecimento de padrões, aproximação de funções, controle e filtragem [5].

A associação de padrões é uma tarefa baseada na característica do cérebro humano realizar tarefas cognitivas, e ela pode assumir duas formas: auto-associação ou hetero-associação. Na auto-associação a rede armazena informações relativas à repetição dos padrões submetidos, e a sua capacidade de armazenar e recordar um padrão particular está ligada à aprendizagem não supervisionada. A hetero-associação está relacionada à ligação de padrões arbitrários de entrada e de saída, e o seu tipo de aprendizagem é supervisionado [5].

O reconhecimento de padrões pode ser definido como o processo pelo qual um padrão recebido é atribuído a uma classe dentro de um conjunto. A RNA quando treinada apresenta a capacidade de classificação, tanto para dados que já lhe foram submetidos, quanto para outros inéditos pertencentes a uma população já utilizada.

A aproximação de funções apresenta uma visão de mão dupla da rede neural, considerando que ao receber dados de entrada, a RNA, no treinamento, executa uma função complexa para chegar à saída e conseqüentemente obter os erros e redefinir seus pesos, mas também se pode, a partir das saídas, chegar até as entradas com uma função inversa. É como se invertesse o sentido

da RNA pensando matematicamente na sua função inversa, muito embora ela possa ser muito complexa para podermos representá-la de fato. Esta descrição é feita apenas como analogia.

O controle de uma RNA baseia-se no fato da informação de saída dela ser utilizada como sinal de entrada para outro processo. Isto remete ao controle de plantas industriais, onde se trata a saída de um controlador como entrada para uma planta e a saída desta para ser ajustada com outros parâmetros e servir de correção para que o controlador produza uma nova saída. Como exemplo, pode-se citar o controle de pressão em caldeiras e o controle de vazão.

A filtragem é responsável por separar informações de determinado interesse e grandeza no meio de uma amostra ruidosa. As RNA possuem esta capacidade de separar a somente as informações de interesse em um conjunto com várias entradas, como por exemplo, em um ambiente onde se ouve várias falas, o cérebro concentra-se apenas naqueles sons que despertam interesse naquele espaço de tempo, e neste momento ele está realizando uma filtragem das informações. Assim, uma RNA é também capaz de executar estes procedimentos considerando sua arquitetura e seus aspectos de treinamento.

## 2.5 Algoritmos de Treinamento

Considerando os aspectos de aprendizado e de estruturação das RNA, apresentam-se na literatura vários algoritmos de treinamento, como por exemplo, [5,8,10]:

- a) *Batch training with weight and bias learning rules*
- b) *BFGS quasi-Newton backpropagation*
- c) *Bayesian regularization*
- d) *Cyclical order incremental update*
- e) *Powell-Beale conjugate gradient backpropagation*
- f) *Fletcher-Powell conjugate gradient backpropagation*
- g) *Polak-Ribiere conjugate gradient backpropagation*
- h) *Gradient descent backpropagation*
- i) *Gradient descent with adaptive learning rate backpropagation*

- j) *Gradient descent with momentum backpropagation*
- k) *Gradient descent with momentum & adaptive learning rate backpropagation*
- l) *Levenberg-Marquardt backpropagation*
- m) *One step secant backpropagation*
- n) *Random order incremental update*
- o) *Resilient backpropagation*
- p) *Sequential order incremental update*
- q) *Scaled conjugate gradient backpropagation*

O interesse encontra-se no algoritmo de treinamento de *Levenberg-Marquardt backpropagation*, que está resumido na seção 2.7, que trata da arquitetura adotada no projeto.

## 2.6 Pré e Pós Processamento de Informações

Na organização dos padrões de entrada e de saída podem existir critérios que selecionam estes conjuntos de acordo com regras e restrições estabelecidos pelo projeto de uma rede neural artificial. Depois de formalizadas estas informações, pode haver necessidade de se aplicarem critérios de normalização específicos e mais simples direcionados a estes conjuntos.

Estas técnicas normalmente são utilizadas com o intuito de melhorar o desempenho do treinamento. Um exemplo simples seria a criação de funções que normalizam as entradas e saídas nas faixas de operação da função de ativação do neurônio. Um outro exemplo considerado seria o caso de haver um conjunto de dados de entrada de grande dimensão, onde estes dados de entrada estão correlacionados, ou seja, existe um nível de redundância entre as informações, e poderia ser feita uma transformação utilizando técnicas de filtragem para gerar um novo conjunto eliminando as redundâncias e diminuindo a dimensão do problema.

Na análise ou supervisão da atividade de treinamento, podem-se utilizar funções que comparam os valores obtidos com as respostas desejadas. Nesta comparação podem-se inferir informações para fazer o controle de parada do treinamento tornando-o mais eficiente. Esta pode ser considerada uma técnica de pós-processamento.

## 2.7 RNA e Arquitetura Adotada no Projeto

A arquitetura básica de RNA usada neste estudo foi a *feed-forward multilayer perceptron*, conforme mostra a Figura 2.8.

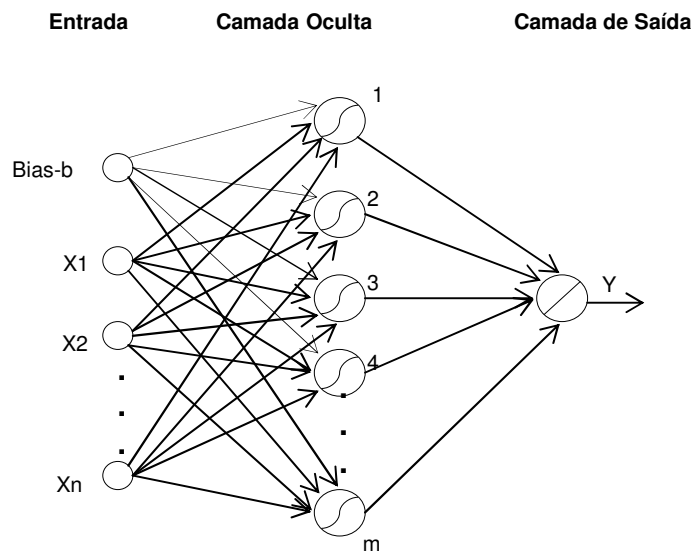


Figura 2.8: Arquitetura de RNA Utilizada

Os *perceptrons* são arranjados em camadas, onde a primeira está conectada às entradas, a segunda é a camada oculta, e a última está conectada à camada de saída.

A camada oculta não possui conexão com o mundo externo (camadas de entrada e saída), e cada *perceptron* de uma camada está conectado a todos os *perceptrons* da camada posterior. Também não há conexões entre *perceptrons* de uma mesma camada. As funções de ativação usadas são tangente hiperbólica nas camadas intermediárias e uma função linear no único neurônio da camada de saída. Na Figura 2.8,  $n$  é o número de dados ou pontos de entrada,  $m$  é o número de neurônios da camada intermediária oculta, e *Bias*  $b$  é o valor de ajuste constante equivalente ao valor um.

O algoritmo de treinamento usado foi o de *Levenberg-Marquardt backpropagation*. O algoritmo *backpropagation* ou retro-propagação trabalha com ajustes dos pesos sinápticos e *bias* pela derivada do erro, em toda a rede, e é muito utilizado para treinar as redes do tipo de *perceptrons* de múltiplas camadas (*multilayer perceptron*) [10].

O algoritmo de Levenberg-Marquardt foi incorporado ao *Backpropagation* com o intuito de melhorar o desempenho deste no treinamento de RNA do tipo *feed-forward*, e é uma aproximação do método de Newton com modificações no cálculo da matriz Hessiana.

Considere a rede da Figura 2.8, modificada para a Figura 2.9 para representar mais detalhadamente uma RNA *multilayer perceptron*.




Figura 2-9: Arquitetura detalhada da RNA Utilizada

A seguir será apresentado resumidamente o algoritmo *Backpropagation*, e as modificações introduzidas pelo método de Levenberg-Marquardt [10]. Fazendo o equacionamento de acordo com o algoritmo *Backpropagation* tem-se:

$$n^{k+1}(i) = \sum_{j=1}^{S_k} w^{k+1}(i, j) p(j) + b^{k+1}(i) \quad (2.8)$$

onde:

$k=0,1$ , e tem-se  $M=2$ , pois somente está configurada uma camada intermediária e uma camada de saída

$w$ : peso sináptico

$p$ : entrada

$b$ : *bias* do nível  $k+1$

$Sk$ : número de neurônios do *layer k*

$j$ :  $j$ -ésimo neurônio

$i$ :  $i$ -ésima entrada  $p$

A saída consolidada seria:

$$\underline{a}^{k+1}(j) = f^{k+1}(\underline{n}^{k+1}(j)) \quad (2.9)$$

:

Para a RNA com dois *layers*:

$$\underline{a}^0 = \underline{p} \quad (2.10)$$

$$\underline{a}^{k+1} = \underline{f}^{k+1}(\underline{w}^{k+1} \underline{a}^k + \underline{b}^{k+1}) \quad (2.11)$$

$k=0,1$

Considerando que temos uma tarefa de aprendizado a ser executada considerando os pares de entradas e saídas, tem-se:

$\{(\underline{p}_1, \underline{t}_1), (\underline{p}_2, \underline{t}_2), \dots, (\underline{p}_Q, \underline{t}_Q)\}$ , o índice de performance da rede é dados por:

$$V = \frac{1}{2} \sum_{q=1}^Q (\underline{t}_q - \underline{a}_q^M)^T (\underline{t}_q - \underline{a}_q^M) = \frac{1}{2} \sum_{q=1}^Q \underline{e}_q^T \underline{e}_q \quad (2.12)$$

onde  $\underline{a}_q^M$  é a saída de rede da  $q$ -ésima entrada  $\underline{p}_q$  e o termo  $(\underline{t}_q - \underline{a}_q^M)$  é o erro da  $q$ -ésima entrada. Para o algoritmo padrão de *backpropagation*, é utilizado um índice aproximado dado pela equação 2.13:

$$\hat{V} = \frac{1}{2} \underline{e}_q^T \underline{e}_q \quad (2.13)$$

O passo aproximado (gradiente) para os pesos sinápticos e *bias* é:

$$\Delta W^k(i, j) = -\alpha \frac{\partial \hat{V}}{\partial W^k(i, j)} \quad (2.14)$$

$$\Delta \mathbf{b}^k(i) = -\alpha \frac{\partial \hat{V}}{\partial \mathbf{b}^k(i)} \quad (2.15)$$

onde  $\alpha$  é a taxa de aprendizagem, e define:

$$\delta^k(i) \equiv \frac{\partial \hat{V}}{\partial \mathbf{n}^k(i)} \quad (2.16)$$

como o índice de performance para promover uma mudança na entrada  $i$  no *layer*  $k$ , e utilizando as equações (2.8), (2.13) e (2.16) mostra-se que:

$$\frac{\partial \hat{V}}{\partial \mathbf{w}^k(i, j)} = \frac{\partial \hat{V}}{\partial \mathbf{n}^k(i)} \frac{\partial \mathbf{n}^k(i)}{\partial \mathbf{w}^k(i, j)} = \delta^k(i) a^{k-1}(j) \quad (2.17)$$

$$\frac{\partial \hat{V}}{\partial \mathbf{b}^k(i)} = \frac{\partial \hat{V}}{\partial \mathbf{n}^k(i)} \frac{\partial \mathbf{n}^k(i)}{\partial \mathbf{b}^k(i)} = \delta^k(i) \quad (2.18)$$

O equacionamento acima satisfaz a relação recorrente representada por:

$$\underline{\delta}^k = \dot{F}^k(\underline{\mathbf{n}}^k) \mathbf{W}^{k+1T} \underline{\delta}^{k+1} \quad (2.19)$$

onde:

$$\dot{F}^k(\underline{\mathbf{n}}^k) = \begin{bmatrix} \dot{f}^k(\mathbf{n}^k(1)) & 0 & \cdots & 0 \\ 0 & \dot{f}^k(\mathbf{n}^k(2)) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \dot{f}^k(\mathbf{n}^k(\mathcal{S}_k)) \end{bmatrix} \quad (2.20)$$

$$\text{e } \dot{f}^k(\mathbf{n}) = \frac{df^k(\mathbf{n})}{dn} \quad (2.21)$$

Esta relação recorrente é inicializada no último *layer* como:

$$\underline{\delta}^M = -\dot{F}^M(\underline{\mathbf{n}}^M) \begin{pmatrix} \mathbf{t} \\ -\mathbf{a} \end{pmatrix} \quad (2.22)$$

Com equacionamento montado, o algoritmo *backpropagation* segue os seguintes passos:



- a) Propaga a entrada para frente usando as equações (2.10) e (2.11)
- b) Propaga a correção para trás, usando as equações (2.22) e (2.19)
- c) Atualiza os pesos e passos usando as equações (2.14), (2.15), (2.17) e (2.18).

A partir deste ponto será introduzida a formulação do algoritmo de Levenberg-Marquardt.

Considere uma função  $V(\underline{x})$  que necessita ser minimizada em relação parâmetro  $\underline{x}$ . O método de Newton será [10]:

$$\Delta \underline{x} = -[\nabla^2 V(\underline{x})]^{-1} \nabla V(\underline{x}) \quad (2.23)$$

onde  $\nabla^2 V(\underline{x})$  é a matriz Hessiana,  $\nabla V(\underline{x})$  é o gradiente, e:

$$V(\underline{x}) = \sum_{i=1}^N e_i^2(\underline{x}) \quad (2.24)$$

$$\nabla V(\underline{x}) = J^T(\underline{x}) \underline{e}(\underline{x}) \quad (2.25)$$

$$\nabla^2 V(\underline{x}) = J^T(\underline{x}) J(\underline{x}) + S(\underline{x}) \quad (2.26)$$

e  $J(\underline{x})$  é a matriz Jacobiana

$$J(\underline{x}) = \begin{bmatrix} \frac{\partial e_1(\underline{x})}{\partial x_1} & \frac{\partial e_1(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_1(\underline{x})}{\partial x_n} \\ \frac{\partial e_2(\underline{x})}{\partial x_1} & \frac{\partial e_2(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_2(\underline{x})}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(\underline{x})}{\partial x_1} & \frac{\partial e_N(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_N(\underline{x})}{\partial x_n} \end{bmatrix} \quad (2.27)$$

$$S(\underline{x}) = \sum_{i=1}^N e_i(\underline{x}) \nabla^2 e_i(\underline{x}) \quad (2.28)$$

Para o Método de Gauss-Newton assume-se que  $S(\underline{x}) \approx 0$ , e a atualização será:

$$\Delta \underline{x} = -[J^T(\underline{x})J(\underline{x})]^{-1} J^T(\underline{x})\underline{e}(\underline{x}) \quad (2.29)$$

A versão da equação acima para o algoritmo de Levenberg-Marquardt é:

$$\Delta \underline{x} = - \left[ J^T(\underline{x})J(\underline{x}) + \mu I \right]^{-1} J^T(\underline{x})\underline{e}(\underline{x}) \quad (2.30)$$

O algoritmo de Levenberg-Marquardt modifica o método de Newton incluindo o termo  $\mu I$  no equacionamento, e o termo  $\mu$  é multiplicado por um fator  $\beta$  sempre que o passo aumentar o valor de  $V(\underline{x})$ . Quando o passo diminuir  $V(\underline{x})$ , o termo  $\mu$  é dividido pelo fator  $\beta$ . Existe uma relação entre  $\mu$  e  $\beta$ . Se o valor de  $\mu$  for grande o algoritmo se transforma em algoritmo de passo, com o passo equivalente a  $1/\mu$ , e se  $\mu$  possuir um valor pequeno o algoritmo se transforma em Gauss-Newton, o algoritmo de Levenberg-Marquardt pode ser considerado como uma modificação nas restrições do algoritmo de Gauss-Newton.

A chave do algoritmo de Levenberg-Marquardt está no calculo da matriz Jacobiana, considerando modificações no algoritmo *Backpropagation*. A equação (2.12) fornece o índice de performance para o problema e comparando com a equação (2.24) pode-se dizer que são similares onde:

$$\underline{x} = [ w^1(1,1) w^1(1,2) \dots w^1(S_1,R) b^1(1) \dots ( b^1 S_1 w^2(1,1) \dots b^M(S_M) ]^T \quad (2.31)$$

e  $N = Q \times S_M$ . E usando o algoritmo padrão *Backpropagation* calcula-se o termo de acordo com:

$$\frac{\partial \hat{V}}{\partial w^k(i,j)} = \frac{\partial \sum_{m=1}^{SM} e_q^2(m)}{\partial w^k(i,j)} \quad (2.32)$$

Para os elementos da matriz Jacobiana, que são necessários para o algoritmo Levenberg-Marquardt, é necessário calcular o termo:

$$\frac{\partial e_q(m)}{\partial w^k(i,j)} \quad (2.33)$$

E pode se usar o algoritmo *Backpropagation* com uma modificação no *layer* final:

$$\Delta^M = -F^{\dot{M}}(\underline{n}^M) \quad (2.34)$$

onde cada coluna da matriz da equação (2.34) é um vetor, que deve ser retro-propagado, através da rede para produzir uma linha da matriz Jacobiana.

Resumidamente o algoritmo de treinamento poderia ser descrito como:

1. Apresentar todos os dados de entrada à rede e calcular as saídas da rede usando as equações (2.10) e (2.11), e os erros com  $(e_q = t_q - a_q^M)$
2. Aplicar a soma do quadrado dos erros sobre as entradas  $V(\underline{x})$  de acordo com a seguinte formulação:
3. Calcular Jacobiana usando as equações (2.34), (2.19), (2.17), (2.18) e (2.27)
4. Resolver  $\Delta x$  usando a equação (2.30)
5. Recalcular a soma dos quadrados usando  $\underline{x} + \Delta x$ .
6. Se o novo valor da soma dos quadrados, for menor que o calculado no passo 1, reduzir o termo  $\mu$  pelo fator  $\beta$ , fazer  $\underline{x} + \Delta x$  e retornar ao passo 1. Se o novo valor da soma dos quadrados for maior que o calculado no passo 1, aumentar o termo  $\mu$  pelo fator  $\beta$ , e retornar ao passo 4.
7. O algoritmo assume que houve convergência quando a norma do gradiente é menor que um valor pré-definido, ou quando a soma dos quadrados foi reduzida a um erro estipulado.

## Capítulo 3

# Determinação de Estado de Operação de um Sistema Elétrico

O cálculo de fluxo de carga ou fluxo de potência em uma rede de energia elétrica consiste essencialmente na determinação do estado de operação da rede (tensões nodais), e posteriormente da distribuição de fluxos de potência. Neste tipo de problema a modelagem é estática, e a rede elétrica é representada por um conjunto de equações algébricas. Esta modelagem é utilizada em situações nas quais, as variações com o tempo são suficientemente lentas para poder se ignorar os efeitos transitórios. A modelagem é feita considerando o estado de operação da rede em regime permanente, e o comportamento dinâmico não é considerado.

Para a modelagem matemática do problema, os componentes do sistema de energia elétrica podem ser classificados de acordo a modelagem barras-ramos em dois grupos: aqueles ligados aos nós, como geradores, cargas, reatores, e capacitores; e aqueles ligados entre dois nós, como linhas de transmissão, transformadores em fase e defasadores.

As equações matemáticas de um fluxo de carga são obtidas com a aplicação da Primeira Lei de Kirchhoff, sobre a conservação das potências ativas e reativas em cada nó da rede, e a Segunda Lei de Kirchhoff é usada para representar os fluxos de potência nos componentes, em função das tensões dos nós terminais da rede.

Existem diversas formulações lineares para resolução do problema de fluxo de carga de forma iterativa, baseados no equacionamento  $I = Y.E$ , onde  $I$  representa o vetor das injeções de correntes,  $Y$  representa a matriz de admitância nodal e  $E$  representa o vetor das tensões nodais. Entre elas estão: Gauss, Gauss-Seidel, Glimm-Stagg, Ward-Hale. Também existem métodos baseados no equacionamento  $E = Z.I$ , onde  $I$  representa o vetor das injeções de correntes, e  $Z$  representa a matriz de impedância nodal, mas os métodos de resolução do fluxo de carga mais conhecidos são os de Newton-Raphson e desacoplados com as versões XB e BX [2].

### 3.1 Contingências

Contingências podem se consideradas as alterações nas redes de energia elétrica, como saídas de operação de linhas de transmissão, cargas, geradores e *shunts* de barra. As contingências podem ser simples, que correspondem à saída de um item da rede elétrica, ou compostas, correspondentes à saída de itens combinados [24]. Estas alterações afetam a rede e conseqüentemente o equacionamento matemático do fluxo de carga e a determinação do estado de uma rede de energia elétrica. Sendo assim, é necessário executar um fluxo de carga todas as vezes que elas ocorrerem para determinar o novo estado de operação da rede.

A análise das contingências é uma tarefa muito importante realizada nos centro de operação e controle, por isto foi considerada em todos os níveis do trabalho, e particularmente estão sendo considerados todos os tipos de contingências simples nas análises [24].

### 3.2 Fluxo de Carga sem Consideração de Controles e Limites

O fluxo de carga sem controles e limites é aquele realizado sem considerar na sua formulação matemática os limites de operação da rede de energia elétrica, como por exemplo, o controle de tensão das barras PV, os limites de tensão em barras PQ, transformadores em fase com controle automático de tap, transformadores defasadores com controle automático de fase, controle de intercâmbio entre áreas, controle de tensão em barras remotas, e cargas variáveis com tensão [24].

Na formulação básica do problema do fluxo de carga associa-se a cada barra da rede quatro variáveis, duas são incógnitas e as outras duas possuem valores conhecidos, onde:

$V_k$  - magnitude da tensão nodal (barra k)

$\theta_k$  - ângulo da tensão nodal

$P_k$  - geração líquida (geração menos carga) de potência ativa

$Q_k$  - injeção líquida de potência reativa

Considerando as variáveis nodais como dados e incógnitas, têm-se três tipos de barras:

PQ – são dados  $P_k$  e  $Q_k$  e calculados  $V_k$  e  $\theta_k$

PV – são dados  $P_k$  e  $V_k$  e calculados  $Q_k$  e  $\theta_k$

REFERÊNCIA – são dados  $V_k$  e  $\theta_k$  e calculados  $P_k$  e  $Q_k$

As barras dos tipos PQ e PV são usadas para representar respectivamente as barras de carga e de geração (incluindo condensadores síncronos). A barra  $V\theta$ , ou barra de referência fornece a referência angular do sistema, e a referência da magnitude da tensão é o próprio nó terra. Além disto, é usada para fechar o balanço de potência do sistema, levando em conta as perdas de transmissão não conhecidas antes de termos a solução final do problema. É a barra onde não temos a especificação da potência ativa.

Estas barras são consideradas as mais comuns e mais importantes nas formulações do fluxo de carga, embora existam outras barras (PQV, P e V) decorrentes de controles e limites aplicados ao problema. A modelagem de cargas também está contemplada na formulação básica do FC-NR, mas aqui considera-se que  $P_k$  e  $Q_k$  são constantes (modelo de potência constante). Neste trabalho não está contemplado no modelo a variação das cargas com a magnitude da tensão nodal.

Seguindo a orientação da primeira lei de Kirchhoff, tem-se que a injeção de potências ativa e reativa em cada barra é igual à soma dos respectivos fluxos que deixam a barra através das linhas de transmissão. Assim têm-se duas equações por barra:

$$P_k = \sum_{m \in \Omega_k} P_{km}(V_k, V_m, \theta_k, \theta_m) \quad (3.1)$$

$$Q_k + Q_k^{sh}(V_k) = \sum_{m \in \Omega_k} Q_{km}(V_k, V_m, \theta_k, \theta_m) \quad (3.2)$$

onde :

$k = 1 \dots NB$ , onde  $NB$  é o número de barras da rede

$\Omega_k$  - conjunto das barras vizinhas da barra  $k$

$V_k, V_m$  - magnitude das tensões das barras terminais do ramo  $k - m$

$\theta_k, \theta_m$  - ângulos das tensões das barras terminais do ramo  $k - m$

$P_{km}$  - fluxo de potência ativa no ramo  $k - m$

$Q_{km}$  - fluxo de potência reativa no ramo  $k - m$

$Q_k^{sh}$  - componente da injeção de potência reativa devido ao elemento *shunt* da barra  $k$ .

Com esta formulação, pode-se dividir o problema do fluxo de carga em dois sub-sistemas, sendo que o primeiro possui a dimensão de  $(2NPQ + NPV)$ , onde  $NPQ$  representa o número de barras PQ, e  $NPV$  representa o número de barras PV. Com este subsistema calcula-se  $V$  e  $\theta$  das barras PQ, e  $\theta$  das barras PV. O segundo subsistema possui dimensão de  $(NPQ)$ , e utiliza as incógnitas obtidas no subsistema um para calcular  $P$  e  $Q$  das barras. O método de solução de fluxo de carga utilizado neste trabalho foi o de Newton-Raphson, mas outras formulações de fluxo de carga poderiam ser utilizadas como os métodos desacoplados BX e XB.

### 3.3 RNA e Fluxo de Carga sem Controles e Limites

As RNA podem ser definidas como sistemas de processamento de informação, compostos por um número variável de objetos singulares (neurônios, células) distribuídos em camadas, que se comunicam através de conjuntos de informações e interconectam-se através de objetos chamados de pesos, compondo uma estrutura genérica e abstrata, com características de aprendizagem, memória e adaptação.

Testes iniciais realizados no trabalho mostraram que a utilização de uma única RNA para calcular todas as grandezas (magnitudes e ângulos de fase das tensões) do sistema é ineficiente devido à dimensão do problema. Testes seguintes foram realizados modelando uma única RNA para calcular todas as magnitudes das tensões e uma única RNA para calcular todos os ângulos de fase das tensões, mostraram-se igualmente insatisfatórios, devido ao problema da dimensão apesar de ter havido uma melhora em relação aos testes anteriores.

Os melhores resultados foram obtidos considerando duas RNAs por cada barra, uma para calcular a magnitude da tensão e outra para calcular o ângulo de fase, conforme representado pela Figura 3.1.




Figura 3.1: Modelo Esquemático da RNA utilizada no FC-RNA.

O FC-RNA calcula o estado de um sistema elétrico usando RNA, representado pela Figura 3.1. O vetor  $x$  representa os dados de entrada,  $G_d$  e  $B_d$  são vetores associados à **diagonal** da matriz de condutância e susceptância modificados. As grandezas  $V$  e  $\theta$  representam as variáveis de saída, contendo as magnitudes e os ângulos de fase das tensões de cada barra respectivamente. As RNAVs representam o conjunto de RNA utilizadas para obter todas as magnitudes das tensões, e as RNA $\theta$ s para obter a magnitude dos ângulos de fase, sem considerar controle e limites. O número de RNAVs é necessária é equivalente ao número de barras PQ, e o número de RNA $\theta$ s necessária é equivalente ao número de barras PQ+PV [21].

O vetor  $x$  representa os dados de entrada,  $G_d$  e  $B_d$  são vetores associados à **diagonal** da matriz de condutância e susceptância modificados,  $m$  é igual ao número de barras PQ,  $n$  é igual ao número de barras PQ e PV.

A vantagem de modelar duas RNAs por barra reside no fato de ser possível treiná-la de forma independente, se necessário, para buscar um resultado melhor das grandezas de cada barra do sistema. Além disso, pode-se alterar a sua configuração de neurônios e camadas de forma independente das outras RNAs que representam as outras barras do sistema.

Assim, a RNA poderá ser utilizada de forma independente nos casos onde é necessário manipular grandezas de uma barra específica. Este tipo de modelagem traz a vantagem para diminuir a dimensão do problema de treinamento [16], e permitir uma análise localizada por barra do sistema e permitir o destacamento da RNA específica da barra para outras análises de forma independente quando necessário.

O modelo de RNA para magnitudes e ângulos de fase das tensões foi definido através de uma composição representada por: uma camada de entrada, uma camada oculta com  $N$  neurônios, com a função de ativação tangente hiperbólica não linear, e uma camada de saída representada por uma função linear com um neurônio. O valor  $N$  é obtido dinamicamente através de treinamento e classificação de diferentes RNAs, ou seja, ele não é fixado, mas obtido através do processo de treinamento onde a comparação de erros de prova auxilia no armazenamento das melhores RNAs. O número de neurônios  $N$  pode variar de acordo com a necessidade de se obter taxas de erros menores, para os dados treinados e de prova. As RNAs que apresentaram melhores taxas de erros, segundo o critério adotado, foram armazenadas juntamente com sua estrutura e definição para uso posterior.



Para o treinamento das RNAs foi utilizado o método de segunda ordem de Levenberg-Marquardt. Este algoritmo é recomendado para contornar situações de convergência para valores de mínimos locais, além de proporcionar uma melhor convergência para as RNAs estudadas [8, 10,17,21].

### **3.4 Metodologia Utilizada no Treinamento das RNAs**

Existe uma sistematização computacional considerável no projeto de implantação de uma RNA para resolver problemas, mas a principal atividade está relacionada à metodologia de treinamento utilizada no projeto de uma RNA.

Anteriormente, foram apresentadas as arquiteturas disponíveis de RNA e as definições e combinações possíveis. Em uma segunda fase foi apresentada a metodologia de aprendizado da RNA.

Considerando estes aspectos esta atividade foi dividida basicamente em seis módulos: 1) definições estruturais, 2) preparação de dados de treinamento, 3) preparação de dados de prova, 4) execução e controle de erros; 5) processamento de resultados, 6) armazenamento das melhores RNAs.

O módulo 1 é responsável por formar a arquitetura da RNA e pela leitura dos dados do sistema de potência. O módulo 2 define as faixas de demanda do sistema de potência que serão analisadas no treinamento, juntamente com lista de contingências e geração dos dados de treinamento. O módulo 3 gera os dados de prova para comprovação dos resultados. O módulo 4 treina as RNAs, para comparar os valores dos erros e armazenar as melhores RNAs. O módulo 5 processa as informações gravadas e mostra os erros obtidos. E, por fim, o módulo 6 armazena todas as definições das RNAs, e os resultados obtidos para uso futuro por outros sistemas e outros estudos a serem realizados.

Foi adotada uma metodologia para a execução dos testes e validação da proposta de utilização de RNA na resolução do problema do FC. Foi realizado um controle rigoroso das taxas de erros, oriundas da comparação entre os dados obtidos através do FC modelado pela RNA, com os resultados de um fluxo de carga Newton-Raphson (FC-NR). O controle dos erros foi realizado com base nas seguintes formulações:

$$e_v^{ij} = \left| V_{NR}^{ij} - V_{RNA}^{ij} \right| \quad (3.3)$$

$$e_\theta^{ij} = \left| \theta_{NR}^{ij} - \theta_{RNA}^{ij} \right| \quad (3.4)$$

$$e_v^{\max} = \max \left\{ e_v^{ij} \right\} \quad (3.5)$$

$$e_\theta^{\max} = \max \left\{ e_\theta^{ij} \right\} \quad (3.6)$$

$$e_v^{av} = \frac{1}{n_b \cdot n_{if}} \sum_{i=1}^{nb} \sum_j^{nif} e_v^{ij} \quad (3.7)$$

$$e_\theta^{av} = \frac{1}{n_b \cdot n_{if}} \sum_{i=1}^{nb} \sum_j^{nif} e_\theta^{ij} \quad (3.8)$$

onde  $i, j, nb, nif, V_{RNA}^{ij}, V_{NR}^{ij}, \theta_{RNA}^{ij}, \theta_{NR}^{ij}, e_v^{\max}, e_v^{av}, e_\theta^{\max}, e_\theta^{av}$  correspondem respectivamente ao número da barra, número do caso de treinamento ou de prova, número total de barras, número total de casos de treinamento ou de prova, magnitude da tensão calculada pela RNA e FC, ângulos de fase calculados pela RNA e FC, erro máximo das tensões, erro médio das tensões, erro máximo dos ângulos, erro médio dos ângulos.

Alguns conceitos são considerados relevantes para a modelagem dos dados de entrada da RNA: a) normalização, b) simplificação, e c) padronização das entradas e saídas. Estes itens são importantes para melhorar o processo de treinamento e teste da RNA [5].

O treinamento é realizado considerando um número máximo de repetições para diversos controles. Neste espaço, é sorteada uma RNA com pesos iniciais e durante o treinamento estes pesos vão sendo aperfeiçoados, visando uma aproximação melhor com a saída esperada, calculada pelo FC-NR. Este processo está ilustrado mais detalhadamente na Figura 3.2.

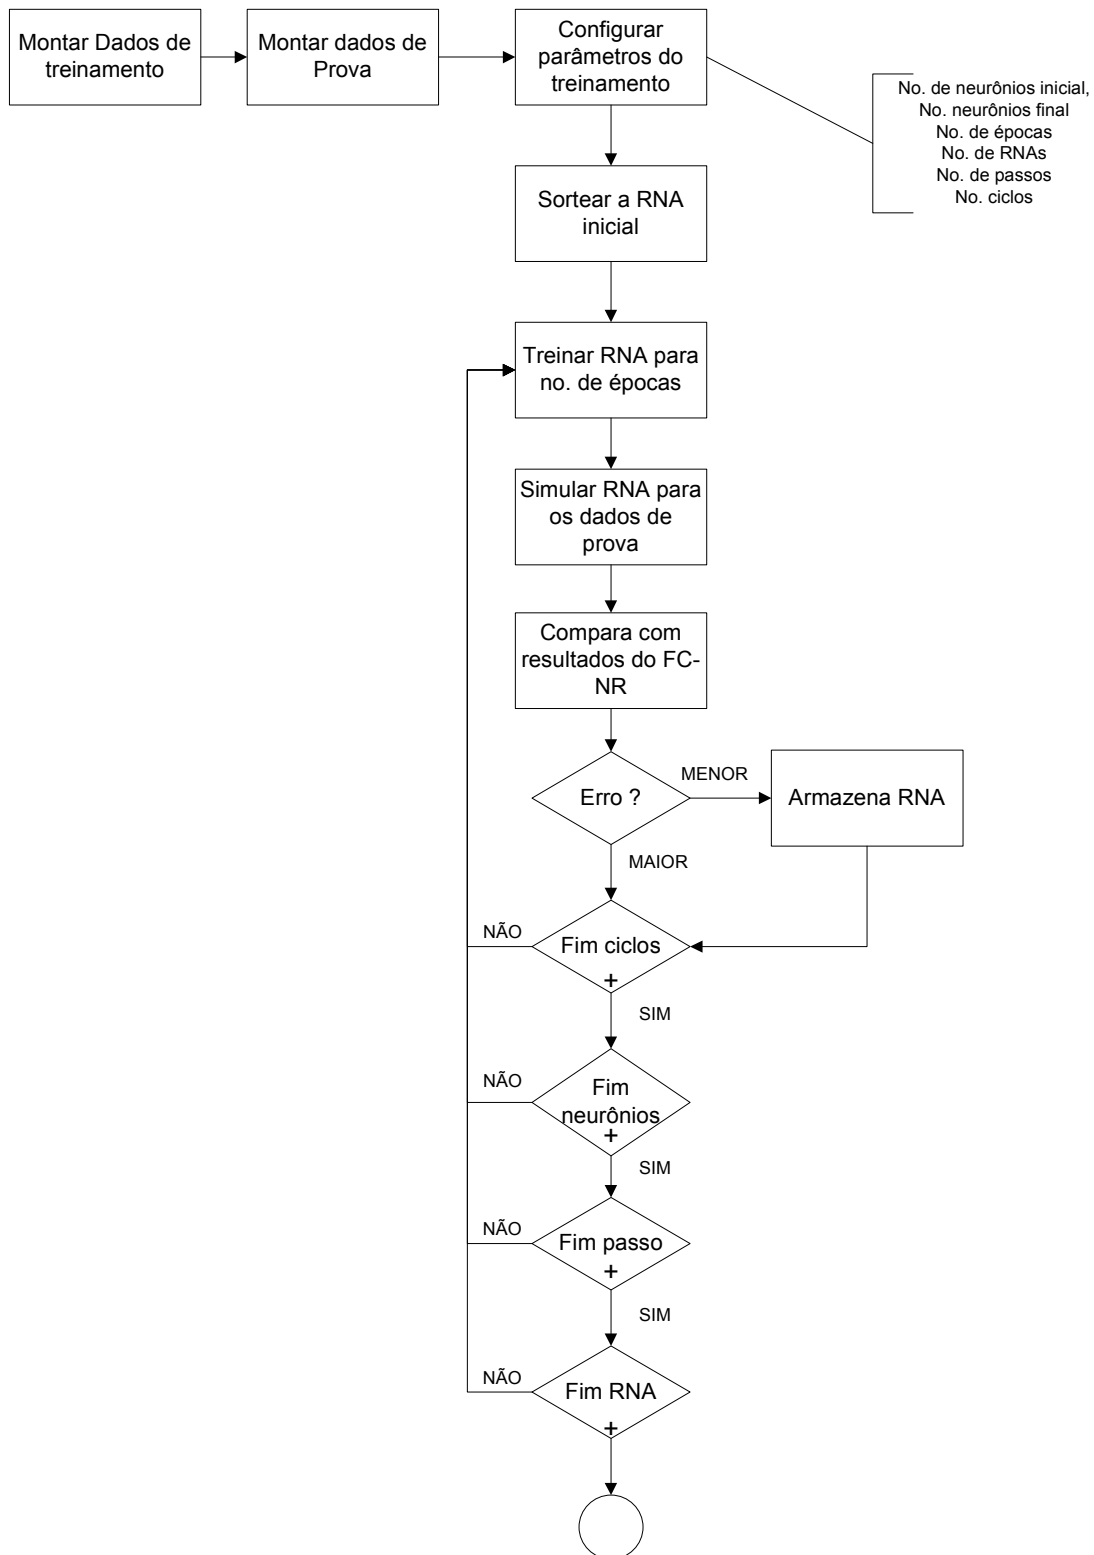


Figura 3-2: Metodologia de Treinamento

O armazenamento das RNAs obtidas através do treinamento propicia a recuperação de sua estrutura podendo ser separada em arquivos as suas dimensões, seus pesos de entrada, *bias* de

entrada, funções de ativação, pesos (das camadas), *bias* de saída, representada por vetores e matrizes, e outras informações que tornem o cálculo das magnitudes das tensões e ângulos mais rápidos depois do processo de treinamento, além de poderem ser exportadas para outros sistemas onde, com operações matemáticas mais elementares pode-se obter as magnitudes das tensões e ângulos de fase, considerando as seguintes equações:

$$s_j = \left( \sum_{i=1}^m x_i^{Norm} \times p_i^j \right) + b^j \quad (3.9)$$

$$tgh(s) = \left( \frac{2}{(1 + e^{-2s})} \right) - 1 \quad (3.10)$$

$$y_{estimado} = \left( \sum_{j=1}^n tgh(s_j) \times p^j \right) + b \quad (3.11)$$

onde:

$m$  : número de entradas

$n$  : número de neurônios da camada intermediária

$i$  :  $i$ -ésima entrada

$j$  :  $j$ -ésima camada

$x_i^{Norm}$ : valor da  $i$ -ésima entrada  $x$  normalizada segundo critérios adotados

$p_i^j$ : valor da  $i$ -ésimo peso da entrada  $x$ , referente à camada  $j$

$b^j$ : valor do *bias* da camada  $j$

$s_j$ : valor da somatória do balanço das entradas  $x$  versus pesos de entrada, ajustado pelo *bias*  $b$  da  $j$ -ésima camada

$tgh(s)$ : tangente hiperbólica de  $s$

$p^j$  : valor o peso da camada  $j$

$b$ : *bias* do neurônio de saída

$y_{estimado}$ : valor se saída  $y$  estimado

### 3.5 FC com RNA (FC-RNA)

As equações básicas e os dados utilizados na modelagem dos dados de entrada são respectivamente:

$$G_d = V_G^2 \cdot G_d^{NORM} - P_D^{NORM} + P_{G_{pv}}^{NORM} + CV_p \quad (3.12)$$

$$B_d = -V_g^2 \cdot B_d^{NORM} - Q_D^{NORM} + CV_q \quad (3.13)$$

No processo de simplificação dos dados de entrada foram consideradas a extração dos elementos das **diagonais** das matrizes de condutância ( $G_d^{NORM}$ ) e susceptância ( $B_d^{NORM}$ ). Esta idéia foi implementada pelo fato dos elementos das diagonais destas matrizes, serem elementos que contêm informação das linhas, transformadores e elementos *shunt* em forma compacta. As mesmas foram normalizadas tomando como base os respectivos valores máximos para o caso base de um fluxo de carga. O mesmo foi feito para normalizar  $P_d$ ,  $Q_d$  e  $P_{g_{pv}}$ . Estes valores foram combinados com: a) a tensão de geração ( $V_g$ ), b) as potências ativas e reativas da demanda ( $P_d$  e  $Q_d$ ), c) a potência de geração das barras PV ( $P_{g_{pv}}$ ), também normalizadas, gerando uma formulação padronizada que remete à formulação das equações de balanço de potência reativa e ativa. Também foram considerados valores de contingência ( $CV_p$  e  $CV_q$ ) fornecendo informação adicional para a RNA, procurando desta forma, compensar a perda de informação dos dados que se encontram fora da diagonal das matrizes de condutância e susceptância. Para a saída de um ramo que conecta as barras  $k$  e  $m$ , coloca-se nas posições  $k$  e  $m$  de  $CV_p$  o valor da condutância do ramo. Coloca-se também o valor da susceptância do ramo nas posições  $k$  e  $m$  de  $CV_q$ . No caso da saída de um elemento *shunt* na barra  $k$ , coloca-se o valor da susceptância do *shunt* na posição  $k$  de  $CV_q$ . Para saída de carga ou gerador na barra  $k$  coloca-se os valores das cargas e geração na posição  $k$  de  $CV_p$  e  $CV_q$ . Estas medidas aceleraram o processo de treinamento da RNA sem prejudicar a precisão dos resultados [5,17].

Para os dados de treinamento, foi considerada uma faixa de demanda entre 0,75 pu e 1,25 pu em torno do caso base. Para os dados de simulação e prova foi considerada uma faixa de demanda entre 0,73 pu e 1,27 pu, levando em conta que os valores de demanda de prova devem ser diferentes das demandas de treinamento. Portanto, para cada valor de demanda de prova e de treinamento tem-se um caso base e um conjunto de contingências. As seguintes situações, não

foram consideradas na montagem dos dados de treinamento e de prova: 1) contingências que produzem ilhas no sistema de energia elétrica, 2) contingências múltiplas, 3) magnitudes de tensões fora dos limites operacionais aceitáveis (menor de 0,75 pu), 4) ângulo de fase fora dos limites operacionais aceitáveis (maior de  $80^\circ$  e menor de  $-80^\circ$ ).

Estes casos não foram considerados porque representam situações extremamente críticas na operação dos sistemas, e para efeitos de análise poderiam não contribuir, podendo ser analisados de forma independente. As contingências múltiplas não foram incluídas nesta análise, mas poderão ser estudadas no futuro.

A composição dos dados de entrada para a RNA proposta foi cuidadosamente selecionada para simular a resolução de um FC. A dimensão dos dados de entrada é  $2nb$ , onde  $nb$  representa o número de barras da rede elétrica a ser analisada.

Foram utilizados na formulação programas de resolução de FC-NR obtidos no próprio Departamento de Sistemas de Energia Elétrica (DSEE), e foram adaptados para fazerem parte do módulo de treinamento das RNA.

Foram desenvolvidos os seguintes componentes sistêmicos: módulos de preparação dos dados de entrada de treinamento e de prova; módulos de treinamento das RNAVs e RNAθs com otimização dos erros das RNAs obtidas; módulo de armazenamento da arquitetura de RNAs; módulo de extração da informação da arquitetura das RNAs; módulo de validação dos resultados simulando um ambiente completo; módulo de processamento de erros e apresentação gráfica.

### 3.6 Testes Realizados FC-RNA

Os sistemas considerados foram: Ward-Hale 6 barras (WH6), sistemas IEEE de 14 barras, 30 barras e de 57 barras, e suas características completas encontram-se no Apêndice 2.

As características resumidas dos sistemas testados como: sua identificação, número de barras e seu tipo, e número de ramos estão resumidos na Tabela 3.1.

Tabela 3.1: Características Gerais dos Sistemas Testados

Sistema	No. de Barras	No. de Ramos	No. de Barras PQ	No. de Barras PV
WH06	6	7	4	1
IEEE014	14	20	9	4
IEEE030	30	41	24	5
IEEE057	57	80	50	6

A dimensão dos dados de entrada foi montada de acordo com a escolha dos dados para treinamento e simulação da RNA, segundo o critério aplicado na variação das demandas nos intervalos definidos para o caso base e as contingências analisadas. Os valores encontram-se na Tabela 3.2. Existe um maior número de casos de simulação do que treinamento para estas redes.

Tabela 3.2: Dimensões dos dados de treinamento e prova FC-RNA

Sistema	Treinamento	Prova
WH06	197	207
IEEE014	612	646
IEEE030	1149	1212
IEEE057	743	864

De acordo com os treinamentos realizados foram determinados dinamicamente as dimensões das camadas ocultas das RNAs dos sistemas utilizados nos testes. A camada de saída foi fixada em todos os casos em um neurônio.

O número de neurônios da camada oculta foi obtido através de testes e comparações dos erros dos dados de prova durante o processo de treinamento contínuo, onde foi variada a composição dos neurônios da camada oculta de forma dinâmica, e armazenadas as redes que apresentaram o menor erro de prova.

A quantidade de neurônios da camada oculta e da camada de saída utilizada para cada RNA envolvida do FC-RNA para cada sistema está na Tabela 3.3.

Tabela 3.3: Dimensões das camadas de neurônios FC-RNA

Sistema	Neurônios da Camada Oculta	Neurônios da Camada de Saída
WH06	12	1
IEEE014	28	1
IEEE030	30	1
IEEE057	35	1

A dimensão do problema está associada ao número de entradas submetidas ao treinamento e ao número de neurônios das camadas ocultas e de saída, assim fazendo uma análise para os sistemas tem-se:

$N_T$ : número de entradas de treinamento

$N_{NO}$ : número de neurônios da camada oculta

$N_{PV}$ : número de barras PV do sistema, juntamente com a barra slack

$N_{NS}$ : número de neurônios da camada de saída

$N_B$ : número de barras do sistema

$N_{PQ}$ : número de barras PQ do sistema

$N_{BIAS}$ : número de entradas bias da rede

A dimensão  $D$  do problema é:

$$D = (2 \cdot N_{PQ} - N_{PV} - 1) (2 \cdot N_T \cdot N_B \cdot N_{NO} + N_{NO} \cdot N_{NS} + N_{BIAS}) \quad (3.14)$$

Para o sistema WH6 considerando todo o espaço de treinamento tem-se:

$N_T$ : 194

$N_{NO}$ : 12

$N_{NS}$ : 1

$N_B$ : 6

$N_{PQ}$ : 4

$N_{PV}$ : 2

$N_{BIAS}$ : 2, um para a camada oculta e outro para a camada de saída

**$D = 27940$**



Os erros máximos absolutos e médios absolutos foram extraídos através da comparação dos dados obtidos pelo FC-RNA com os dados do FC-NR, considerando todos os casos de treinamento e simulação. Os valores dos erros obtidos para as tensões das barras PQ e a magnitude dos ângulos de fase para treinamento encontram-se respectivamente nas Tabelas 3.4 e 3.5, e para prova encontram-se respectivamente nas Tabelas 3.6 e 3.7.

Tabela 3.4: Resultados do Treinamento das RNAVs para as magnitudes das tensões

Sistema	Erros Absolutos de Treinamento Tensões	
	Máximo (pu)	Médio (pu)
WH06	0,000693	0,000146
IEEE014	0,000154	0,000003
IEEE030	0,000882	0,000014
IEEE057	0,001194	0,000033

Tabela 3.5: Resultados do Treinamento das RNA $\theta$ s para as magnitudes dos ângulos

Sistema	Erros Absolutos de Treinamento Ângulos	
	Máximo (rad)	Médio (rad)
WH06	0,000766	0,000115
IEEE014	0,000055	0,000001
IEEE030	0,000063	0,000001
IEEE057	0,001935	0,000039

Tabela 3.6: Resultados de Prova RNAVs para as magnitudes das tensões

Sistema	Erros Absolutos de Prova Tensões	
	Máximo (pu)	Médio (pu)
WH06	0,000960	0,000238
IEEE014	0,000466	0,000003
IEEE030	0,000784	0,000015
IEEE057	0,004432	0,000041

Tabela 3.7: Resultados de Prova RNAθs para as magnitudes dos ângulos

Sistema	Erros Absolutos de Prova Ângulos	
	Máximo (rad)	Médio (rad)
WH06	0,000986	0,000203
IEEE014	0,000746	0,000002
IEEE030	0,000978	0,000002
IEEE057	0,004068	0,000054

Considerando que o objetivo inicial era obter o menor erro máximo possível, para cada uma das RNAs, o treinamento foi ajustado para considerar uma grandeza do erro da ordem de  $10^{-3}$ , e os resultados obtidos mostram que as taxas de erros máximos absolutos e erros médios absolutos apresentaram valores baixos. Para o cálculo dos erros foram usadas as formulações da seção 3.5 para a modelagem do problema do FC-RNA.

Cabe ressaltar que, caso haja necessidade de melhorar estes erros para o cálculo da magnitude da tensão ou ângulo de fase de uma determinada barra, pode-se modelar a rede com mais neurônios ou mais camadas e ainda treiná-la de forma independente, ou refazer o treinamento tendo como ponto de partida a última rede armazenada, um exemplo disto é o caso das barras cujo resultado produzir um valor que interfira de forma mais expressiva na média. Para o estudo dos dados de prova, foram atribuídas demandas diferentes e fora do intervalo das demandas de treinamento. Além disso, deve-se considerar que é suficiente que a RNA seja capaz de obter resultados precisos em uma faixa de operação em torno dos valores especificados na curva de previsão de carga.

### 3.7 Fluxo de Carga com Controles e Limites

Na formulação do fluxo de carga considerando a atuação de dispositivos de controle e os limites de operação dos equipamentos, pode-se considerar como os mais comuns os seguintes controles: controle da magnitude de tensão de barra (local ou remota) através da injeção de reativos, controle da magnitude de tensão em barra (local ou remota) por ajuste da posição de

*taps* de transformadores em fase, controle de fluxo de potência ativa em transformadores defasadores, controle de intercâmbio de potência entre áreas, limite de injeção de potência reativa em barras PV, limite de magnitude de tensão em barras PQ e limite de posição de *taps* em transformadores [24].

O fluxo de carga com controles e limites é aquele realizado considerando pelo menos um controle ou limite dentre os possíveis relacionados anteriormente. Possui uma formulação parecida com o fluxo de carga sem controles e limites. Seus controles e limites podem ser representados utilizando informações de classificação de barras (PQ, PV e V $\theta$ ), e a possibilidade de trocar a sua definição, aplicar ajustes alternados nas variáveis de controle que são realizados após um número  $n$  de iterações, e ajustes simultâneos que podem ser representados incorporando novas equações ao subsistema 1 de equações do fluxo de carga, ou ainda na substituição de variáveis dependentes do subsistema 1 por novas equações e variáveis [24].

No trabalho em questão foi implementado o controle das tensões nas barras PV através da injeção de potência reativa nas barras. Este controle está ligado às barras que contêm geradores ou compensadores síncronos. Nestas barras, o controle da magnitude da tensão é feito através do ajuste da corrente de campo de máquinas síncronas [24]. No fluxo de carga o reflexo deste controle se dá através de comparativos sobre o intervalo da potência reativa mínima e máxima. Se em cada iteração do fluxo de carga for necessário aumentar ou diminuir a potência reativa para manter a tensão no valor especificado, e assim infringir a fronteira do limite, haverá uma mudança de tipo de barra, sendo que a barra PV passa a ser PQ, e muda-se a matriz Jacobiana do problema e sua dimensão, e assim sucessivamente considerando a dinâmica da variação da potência reativa e o critério de classificação do tipo da barra.

A formulação inserida no algoritmo do fluxo de carga é a seguinte:

$$V_k = V_k^{esp} \quad (3.14)$$

$$Q_k^{\min} \leq Q_k^{cal} \leq Q_k^{\max} \quad (3.15)$$

Este equacionamento faz com que seja possível modificar o tipo da barra de PV para PQ, e assim alteramos a dimensão do problema em relação à formulação original sem a violação do limite.

A introdução de controles e limites na formulação provoca um aumento da complexidade do fluxo de carga, podendo ocasionar problemas de convergência na solução, diretamente ligados ao número de controles incluídos no problema. Normalmente, o processo iterativo exige mais iterações para a convergência, podendo haver divergência da solução ou até a obtenção de múltiplas soluções. Esta situação exige que técnicas de controle dos ajustes sejam implementadas cuidadosamente.

No apêndice I do trabalho existe uma menção e uma formulação reduzida e simplificada de como poderiam ser tratados e implementados outros controles e limites no FC-RNA.

### 3.8 FC com Controle de Limites e RNA (FC-RNA-CTRL)

Na modelagem inicial do FC-RNA-CTRL foi considerado inicialmente o mesmo processo do fluxo de carga sem controles e limites com RNA, e apenas foi trocado o fluxo de carga básico por um FC com controle para a geração dos dados de referência, e alterada a dimensão do problema considerando RNAs adicionais para cálculo das tensões das barras PV. Todos os processos de treinamento foram mantidos. Este método apresentou-se ineficiente, pois na interpretação da RNA as barras PV possuíam tensão inalterada e fixa em um valor o que causou problemas na generalização da RNA, provocando erros muitos altos nos dados de simulação, prova e de treinamento. O motivo deste problema está relacionado ao padrão criado pela RNA para determinadas faixas de demanda e contingência, onde no treinamento não houve violação de limites e na prova ocorreu violação de limites, e vice-versa.

Na análise do problema chegou-se a modificar a arquitetura da rede suspeitando de insuficiência de camadas e neurônios para generalização adequada.

Após várias combinações de arquiteturas e análises modificou-se o raciocínio empregado, e foi incluído um *flag* indicador de violação de limite, que resultou em uma melhora dos erros, mas não o suficiente para expectativas. Evoluindo na formulação resolveu-se colocar a variação da potência reativa nos dados de entrada da RNA, colocando o termo ( $Q_c-Q_g$ ) na equação 3.13, e manteve-se o mesmo número de RNAs, e apenas foi trocado o fluxo de carga normal por um FC com controle, e alterada a dimensão do problema considerando RNAs adicionais para cálculo das tensões das barras PV e foram mantidos todos os processos de treinamento, e mesmo assim os erros não melhoraram.

No final foi separada a análise do problema em duas partes distintas, casos sem violação e casos com violação, e adicionar a variação da potência reativa como dado de entrada, modificando a dimensão do problema, e também utilizar o valor das tensões calculadas pelo FC-RNA.

Portanto o FC-RNA-CTRL calcula o estado do sistema usando RNA considerando os controles de limites de tensão nas barras PV e utiliza o FC-RNA básico em sua formulação. Depois de calcular o estado do sistema com FC-RNA é calculada a geração de potência reativa nas barras PV. Se não houve violação na geração de potência reativa, o estado do sistema é dado pelo resultado do FC-RNA; se houve violação, os dados originais do FC-RNA mais a quantidade de violação de potência reativa dos geradores são separados para compor um outro padrão de dados de entrada que farão parte de uma RNA-CTRL. No entanto, a dimensão do FC-RNA foi modificada para atender o FC-RNA-CTRL. Agora, a dimensão será é igual a  $2nb$  mais o número de barras PV, e têm-se quatro grupos de RNAs.

O FC-RNA-CTRL está representado na Figura 3.3, e a formulação é similar à da seção 3.5. As RNAV-CTRL representam o conjunto de RNAs utilizadas para obter as magnitudes das tensões das barras PV+PQ, e as RNA $\theta$ -CTRL para obter a magnitude dos ângulos de fase das barras PV+PQ.

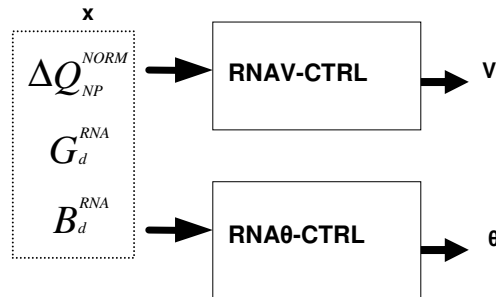


Figura 3.3: Modelo Esquemático da RNA utilizada no FC-RNA-CTRL.

O número de RNA utilizadas para calcular as tensões no FC-RNA é igual ao número de barras PQ, no entanto no FC-RNA-CTRL, as tensões das barras PV são calculadas para atender os limites de tensão nas barras PV.

$$\Delta Q_{NPV}^{NORM} \tag{3.16}$$

$$G_d^{RNA} = V_{RNA}^2 \cdot G_d^{NORM} - P_D^{NORM} + P_{G_{pv}}^{NORM} + CV_p \quad (3.17)$$

$$B_d^{RNA} = -V_{RNA}^2 \cdot B_d^{NORM} - Q_D^{NORM} + CV_q \quad (3.18)$$

O valor de  $\Delta Q_{NPV}^{NORM}$  representa a violação de potência reativa nas barras PV, e foi normalizada com base nos valores máximos absolutos. Se não houve violação esse valor é zero. As tensões de geração  $V_{RNA}$  nas Equações (3.17) e (3.18) foram obtidas usando o FC-RNA, e assim pode-se substituir a tensão das barras PV levando em conta as barras consideradas constantes no FC-RNA.

Para o treinamento da RNA, foram considerados os mesmos casos do FC-RNA da seção 3.5. Todos os casos onde houve violação ou não de limites no FC-RNA foram utilizados para treinar as RNA-CTRL. A decisão de considerar os casos onde não houve violação foi adotada para não empobrecer a amostra considerando que na maior parte dos casos tem-se uma amostra menor de dados onde ocorre violação de limites. Separando a análise podem-se usar os modelos de rede de acordo com a necessidade do problema, conforme ilustra a Figura 3.4.

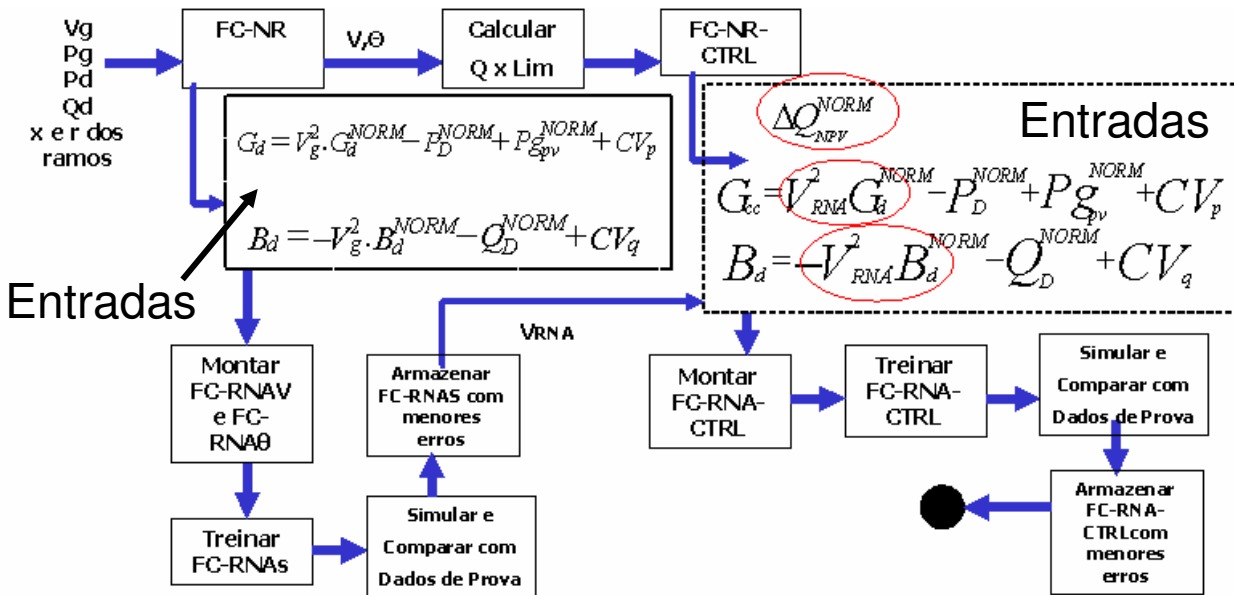


Figura 3.4: Diagrama de Blocos FC-RNA-CTRL.

Foram utilizados na formulação programas de resolução de FC-NR com controle de limites obtidos no próprio departamento de sistemas de energia elétrica DSEE, e foram adaptados para fazerem parte do módulo de treinamento das RNAs.

Foram desenvolvidos os seguintes componentes sistêmicos análogos ao FC-RNA: módulos de preparação dos dados de entrada de treinamento e de prova; módulos de treinamento das RNAVs-CTRL e RNA $\theta$ s-CTRL com otimização dos erros das RNAs obtidas; módulo de armazenamento da arquitetura de RNAs-CTRL; módulo de extração da informação da arquitetura das RNAs-CTRL; e o módulo de validação dos resultados simulando um ambiente completo; módulo de processamento de erros e apresentação gráfica.

### 3.9 Testes Realizados FC-RNA-CTRL

Os testes e simulações apresentados nesta seção seguiram o mesmo padrão apresentado na seção 3.5.

A dimensão dos dados de entrada e de simulação foi montada de acordo com a escolha dos dados para treinamento e simulação da RNA-CTRL. Isto foi realizado segundo um critério aplicado na variação das demandas nos intervalos definidos, para o caso base e as contingências analisadas, para cada um dos sistemas utilizados nos testes. Estes valores e o número de violações dos limites de tensão das barras PV mapeados, encontram-se na Tabela 3.8. Existe um maior número dos casos de simulação do que treinamento.

Tabela 3.8: Dimensões dos dados de treinamento e prova RNA-CTRL

<b>Sistema</b>	<b>Casos de Treinamento</b>	<b>Casos de Prova</b>	<b>Violações treinamento/prova</b>
WH06	197	207	52/52
IEEE014	612	646	220/241
IEEE030	1149	1212	550/593
IEEE057	743	864	671/747

A quantidade de neurônios da camada oculta de cada sistema utilizado nos testes, também foi determinada dinamicamente no treinamento assim como na seção 3.5. A quantidade de neurônios da camada de saída foi fixada em um neurônio, e estes dados encontram-se na Tabela 3.9.

Tabela 3.9: Dimensões das camadas de neurônios RNA-CTRL

Sistema	Neurônios da Camada Oculta	Neurônios da Camada de Saída
WH06	06	1
IEEE014	07	1
IEEE030	07/08/09	1
IEEE057	07/08/09	1

O número de neurônios da camada oculta das redes RNAs-CTRL utilizadas para o FC-RNA-CTRL são menores do que as RNAs utilizadas para o FC-RNA. O treinamento que determinou dinamicamente estes valores priorizou a generalização, considerando que existe para os sistemas testados, uma quantidade menor de casos onde houve violação de limites nos dados de treinamento e de prova. Para não empobrecer a amostra foram adicionados casos onde não houve violação, e assim estas foram as RNAs-CTRL treinadas que apresentaram melhor resultado.

Os erros máximos absolutos e médios absolutos para os valores da tensão e ângulo de fase, foram obtidos comparando-se os resultados do FC-NR com FC-RNA-CTRL para os dados de treinamento e prova, e encontram-se nas Tabelas 3.10, 3.11, 3.12 e 3.13 respectivamente

Tabela 3.10: Resultados dos Erros de Treinamento RNAs-CTRL

Sistema	Dados de Treinamento Tensões	
	Erro Máximo Absoluto (pu)	Erro Médio Absoluto (pu)
WH06	0,001018	0,000147
IEEE014	0,005612	0,000172
IEEE030	0,018794	0,000387
IEEE057	0,019024	0,000659



Tabela 3.11: Resultados dos Erros de Treinamento RNA $\theta$ s-CTRL

	<b>Dados de Treinamento Ângulos</b>	
<b>Sistema</b>	Erro Máximo Absoluto (rad)	Erro Médio Absoluto (rad)
WH06	0,003325	0,000152
IEEE014	0,008719	0,000182
IEEE030	0,015520	0,000134
IEEE057	0,020828	0,000608

Tabela 3.12: Resultados dos Erros de Prova RNAVs-CTRL

	<b>Dados de Prova Tensões</b>	
<b>Sistema</b>	Erro Máximo Absoluto (pu)	Erro Médio Absoluto (pu)
WH06	0,004508	0,000176
IEEE014	0,008763	0,000348
IEEE030	0,019253	0,000519
IEEE057	0,022258	0,001078

Tabela 3.13: Resultados dos Erros de Prova RNA $\theta$ s-CTRL

	<b>Dados de Prova Ângulos</b>	
<b>Sistema</b>	Erro Máximo Absoluto (rad)	Erro Médio Absoluto (rad)
WH06	0,006912	0,000195
IEEE014	0,009696	0,000325
IEEE030	0,022309	0,000238
IEEE057	0,034773	0,001236

Os erros absolutos obtidos foram maiores do que os erros absolutos apresentados pelo FC-RNA. O motivo dos erros terem sido maiores pode estar relacionado a problemas de generalização, considerando casos onde no treinamento houve violação de limites para uma determinada faixa de demanda e na prova não, ou também o caso contrário. Estas RNAs foram

também remodeladas e treinadas com um conjunto maior de neurônios e de camadas, mas não produziram resultados melhores.

Ainda não foi apresentada na literatura uma metodologia para resolver o FC-NR com controles de limites utilizando RNA.

Para ilustrar graficamente os resultados das tensões, foi escolhida a barra 28 do sistema IEEE057, que apresentou o maior erro absoluto das tensões na comparação entre o FC-NR e o FC-RNA-CTRL. Analogamente para os ângulos, foi escolhida a barra 8 do sistema IEEE057, que apresentou o maior erro absoluto dos ângulos na comparação entre o FC-NR e o FC-RNA-CTRL.

A Figuras 3.5 e 3.6 ilustram respectivamente os resultados obtidos para as tensões e ângulos.

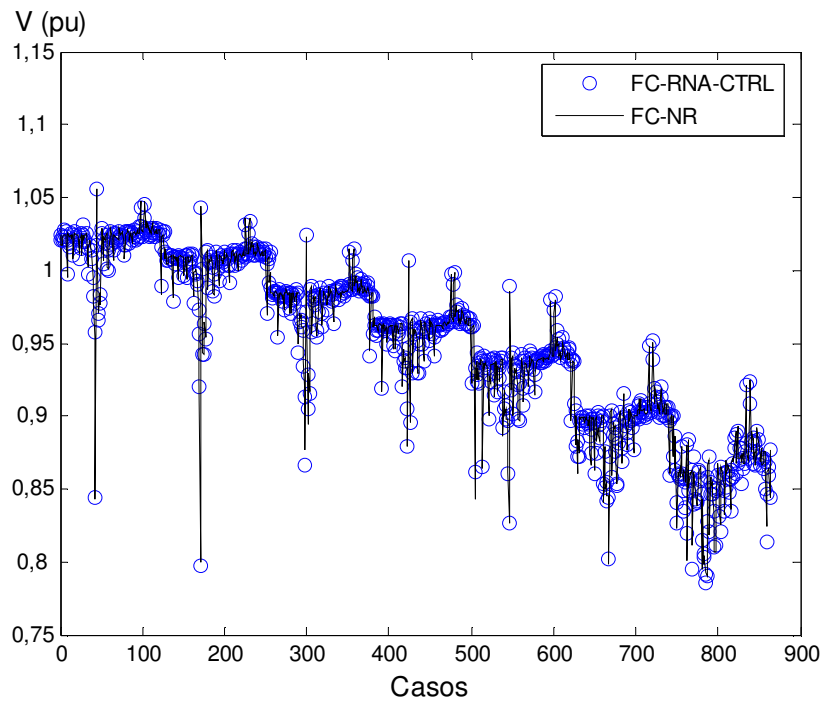


Figura 3.5: Tensões da barra 28 do sistema IEEE057, que apresentou o maior erro.




Figura 3.6: Ângulos de fase da barra 8 do sistema IEEE057, que apresentou o maior erro.

Para se ter uma análise geral relativa aos resultados das tensões e dos ângulos, foram escolhidos as tensões e ângulos calculados pela FC-RNA-CTRL de todas as barras, que apresentaram os piores erros absolutos na comparação entre o FC-NR e o FC-RNA-CTRL, mostrando os valores obtidos pelos dois FCs. As Figuras 3.7 e 3.8 ilustram os resultados obtidos.




Figura 3.7: Piores resultados das tensões da rede IEEE57 classificados por barra.

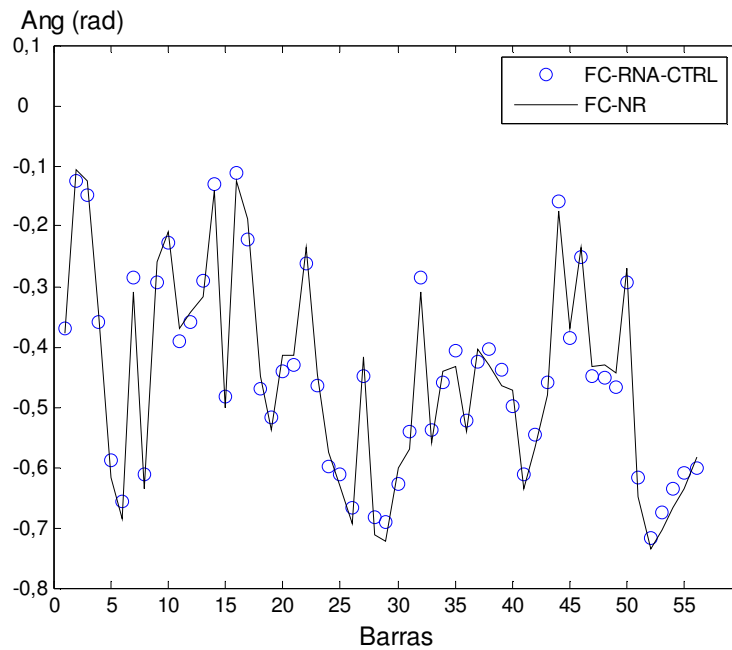


Figura 3.8: Piores resultados dos ângulos de fase da rede IEEE57 classificados por barra.

Uma outra análise geral foi considerada para os resultados das tensões e dos ângulos relativos ao erro absoluto máximo e o erro absoluto médio de cada barra na comparação entre o FC-NR e o FC-RNA-CTRL, mostrando os valores obtidos do erro máximo e do erro mínimo. As Figuras 3.9 e 3.10 ilustram respectivamente os resultados obtidos.




Figura 3.9: Erros máximos e médios da magnitude da tensão considerando todas as contingências e o caso base, por barra.




Figura 3.10: Erros máximos e médios dos ângulos de fase considerando todas as contingências e o caso base, por barra.

## Capítulo 4

### Inicialização de FC com RNA

Existem sistemas que, ao serem submetidos a determinadas variações de carga e geração, não proporcionam condições de resolução utilizando o método convencional FC. Embora existam questionamentos sobre os casos reais aos quais estes sistemas são expostos [25], para efeitos de estudos não esta sendo considerada esta análise. A idéia principal é treinar uma RNA com dados fornecidos por um fluxo de carga com passo ótimo (cuja descrição básica será feita adiante) para que ela determine grandezas de tensões e ângulos que sirvam de valores iniciais para um fluxo de carga convencional resolver o problema sem a utilização de técnicas adicionais, ou ainda treinar uma RNA com dados fornecidos por um FC-NR convencional, para que ela também determine grandezas de tensões e ângulos que sirvam de valores iniciais para o FC, com objetivo de diminuir o número de iterações.

Também é possível iniciar qualquer sistema independente das técnicas de resolução de fluxo de carga e aplicação de passo ótimo, utilizando a metodologia e os mesmos conceitos básicos de modelagem e arquitetura das RNA.

## 4.1 Fluxo de Carga com Passo Ótimo

É possível que o sistema de equações algébricas correspondente a um sistema elétrico de potência para fins de cálculo de fluxo de carga seja mal condicionado, ou seja, apesar do sistema operar normalmente, os métodos de cálculo de fluxo de carga não atingem a convergência. Podem ocorrer também situações em que há convergência, porém, para um ponto de operação que não corresponde ao real, apesar da inicialização do processo iterativo ser feita da forma convencional.

O método de fluxo de carga com passo ótimo FC-CPO é a técnica aplicada para contornar a dificuldade do fluxo de carga convencional em determinar uma solução para uma rede mal condicionada, onde as suas iterações não convergem para uma solução factível [26], ou simplesmente apresenta um desempenho ruim. O FC-CPO consiste na atualização do vetor de estado  $x$  em uma iteração  $\eta$  dada por:

$$x^{\eta+1} = x^{\eta} + \mu [J(x^{\eta})]^{-1} \Delta S^{\eta}, \quad (4.1)$$

em que  $\Delta S^{\eta}$  é o vetor de *mismatches* de potência ativa e reativa,  $J(x^{\eta})$  é a matriz Jacobiana e  $\mu$  é o multiplicador ótimo, calculado de forma a minimizar uma equação quadrática baseada nos *mismatches* de potência. Para sistema bem condicionados  $\mu$  assume valores próximos de 1, seguindo o comportamento do fluxo de carga convencional. Para sistemas mal condicionados  $\mu$  assume valores com o objetivo de minimizar a função quadrática baseada nos erros das potências (*mismatches*). Nos casos de pontos de operação infactíveis o multiplicador ótimo tende a zero, levando-o a um ponto de operação na fronteira de factibilidade [3, 26].

Neste trabalho específico usa-se um fluxo de carga com a aplicação do método de otimização de passo proposto em [3], cujo desempenho foi confirmada em [27], mas outros algoritmos de otimização de passo poderiam ser utilizados como alternativa.

O FC-CPO pode ser considerado como uma alternativa ao fluxo convencional, nos casos em que este não fornece soluções factíveis do estado da rede, embora seja considerado mais complexo, e requerer um esforço computacional um pouco maior [3].

## 4.2 Fluxo de Carga CPO e RNA (FC-RNA-CPO)

O FC-RNA-CPO é o fluxo de carga que calcula o estado de um sistema elétrico usando RNA, e considerando a otimização do passo, representado pela Figura 4.1. O vetor  $x$  representa os dados de entrada,  $G_d$  e  $B_d$  são vetores associados à diagonal da matriz de condutância e susceptância,  $n$  é igual ao número de barras PQ e PV. Os vetores  $V$  e  $\theta$  representam as variáveis de saída, contendo as magnitudes e os ângulos de fase das tensões de cada barra respectivamente. As RNAVs-CPO representam o conjunto de RNAs utilizadas para obter todas as magnitudes das tensões, e as RNA $\theta$ s-CPO para obter a magnitude dos ângulos de fase.




Figura 4.1: Modelo Esquemático da RNA utilizada no FC-RNA-CPO.

A formulação do problema para tratamento de redes onde é necessário utilizar o fluxo de carga com passo ótimo é similar à análise do FC-RNA, mas no processo não estão sendo considerados os controles, limites e contingências, e assim não se têm os elementos que reforçam a ocorrência de contingências nas equações 4.1 e 4.2. Também foi introduzida a potência reativa de geração na formulação, suprimida na formulação do FC-RNA devido à sua adequação para o controle de limites, onde tem-se:

$$G_d = V_g^2 \cdot G_d^{NORM} - P_C^{NORM} + P_G^{NORM} \quad (4.2)$$

$$B_d = -V_g^2 \cdot B_d^{NORM} - (Q_C^{NORM} - Q_G^{NORM}) \quad (4.3)$$

No processo de simplificação dos dados de entrada também foram consideradas a extração dos elementos das diagonais das matrizes de condutância ( $G_d^{NORM}$ ) e susceptância ( $B_d^{NORM}$ ),



normalizadas, combinadas com a tensão de geração ( $V_g$ ), as potências ativas e reativas da demanda ( $P_C^{NORM}$  e  $Q_C^{NORM}$ ), a potência reativa de geração ( $Q_G^{NORM}$ ) e a potência de geração das barras PV ( $P_{Gpv}^{NORM}$ ) também normalizadas, gerando uma formulação que também remete às equações de balanço de potência reativa e ativa.

### 4.3 Fluxo de Carga Inicializado por RNA

Aplicando conceitos da seção 4.2, foi analisado um sistema cujo FC convencional apresenta problemas de convergência para determinadas faixas de potência reativa de carga e geração. Para resolver este problema é utilizado um FC com passo ótimo [3]. A idéia é formar uma base de informações com os dados do FC com passo ótimo e utilizá-lo para treinar uma RNA-CPO para determinar as variáveis de estado e utilizá-las como entradas para um FC convencional, conforme Figura 4.2.

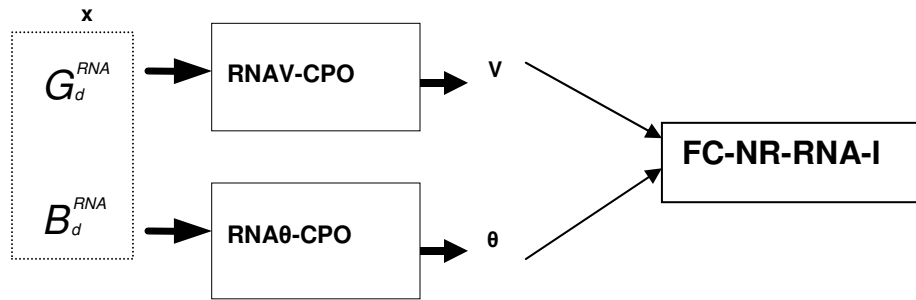


Figura 4.2: Inicialização de um fluxo de carga pela RNA-CPO

O treinamento das RNA foi realizado considerando o processo anteriormente descrito na seção 3.5.

Um aspecto interessante deste processo é que o controle de erros de treinamento pode ser um pouco mais flexível com o objetivo apenas de sugerir o ponto inicial do estado da rede para inicializar um FC, não havendo necessidade de uma precisão mais rigorosa como usada nas seções anteriores.

Após este processo de treinamento, utilizam-se as RNAs armazenadas para efetuar o cálculo das tensões e ângulos de cada barra, submetendo as RNAs a faixas de demandas desconhecidas pelo processo de treinamento, para inicializar um FC-NR sem passo ótimo. Em

poucas iterações tem-se a convergência para casos onde a inicialização *flat-start* não oferecia convergência, ou então exigia muitas iterações. O treinamento das RNA-CPO foi realizado considerando o processo anteriormente descrito para o FC-RNA.

Também foi considerado nos testes uma variante da formulação original usando a formulação sem o passo ótimo, mas aplicando as formulações originais do FC-RNA representada pela Figura 4.3, e testados para um sistema sem problema de condicionamento.

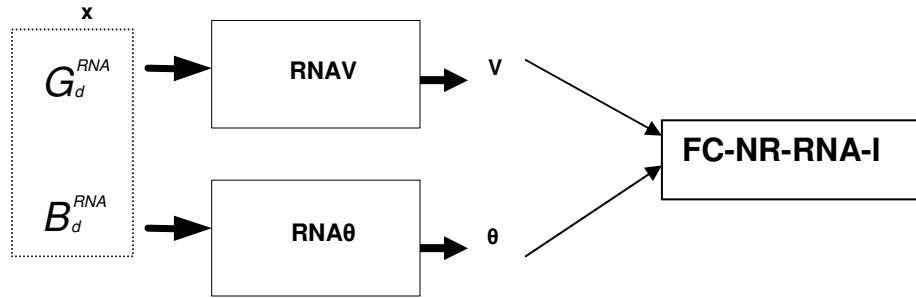


Figura 4.3: Inicialização de um fluxo de carga pela RNA.

Foram utilizados na formulação programas de resolução de FC-RNA-CPO obtidos no próprio departamento de sistemas de energia elétrica DSEE, e foram adaptados para fazerem parte do módulo de treinamento das RNAs.

Foram desenvolvidos os seguintes componentes sistêmicos análogos ao FC-RNA e FC-RNA-CTRL: módulos de preparação dos dados de entrada de treinamento e de prova; módulos de treinamento das RNAVs-CPO e RNAθs-CPO com otimização dos erros das RNAs obtidas; módulo de armazenamento da arquitetura de RNAs-CPO; adaptação de um FC-NR para ser inicializado pela RNA; módulo de extração da informação da arquitetura das RNAs-CPO; e o módulo de validação dos resultados simulando um ambiente completo; módulo de processamento de erros e apresentação gráfica.

#### 4.4 Testes Realizados para o Sistema de 11 barras

Aplicando conceitos descritos nas seções 4.1, 4.2, 4.3, foi analisado um sistema de 11 barras cujos dados são mostrados nas Tabelas 4.1 e 4.2, e cujo FC convencional apresenta problemas de convergência para determinadas faixas de potência reativa de carga e geração. Para resolver este problema é utilizado um FC com passo ótimo [3].

Uma base de informações foi montada com os dados do FC-CPO, e esta foi utilizada para treinar a RNA, com objetivo de determinar as variáveis de estado e utilizá-las como entradas para um FC convencional, conforme os dados das barras do sistema de 11 barras representado pela Tabela 4.1 e os dados dos ramos representados pela Tabela 4.2.

Tabela 4.1: Sistema de 11 barras

Barra	Tipo	$P_{gerada}$ (MW)	$Q_{gerada}$ (MVar)	$P_{carga}$ (MW)	$Q_{carga}$ (MVar)
1	PQ	400	87	0	0
2	PQ	500	165	0	0
3	PQ	0	42	75	0
4	PQ	25	81	0	0
5	PQ	0	0	0	0
6	PQ	0	0	250	11
7	PQ	0	0	200	42
8	PQ	0	123	250	0
9	PQ	0	0	175	3
10	PQ	0	0	375	59
11	Slack	0	0	0	0

Tabela 4.2: Ramos do sistema de 11 barras

de	para	r (pu)	x (pu)	bsh (pu)
1	6	0,004000	0,080000	0,35000
2	7	0,000001	0,050000	0,00000
3	9	0,005000	0,100000	0,00000
4	10	0,003000	0,050000	0,02000
5	6	0,001000	0,027000	0,21400
5	8	0,000800	0,033000	0,18100
5	10	0,005000	0,100000	0,30000
5	11	0,002000	0,100000	0,40000
6	8	0,000220	0,005000	0,02200
7	8	0,003000	0,050000	0,14000
8	9	0,002300	0,030800	0,11220
9	10	0,001200	0,032000	0,12840

Após este processo de treinamento, utilizam-se as RNAs obtidas para o sistema de 11 barras, para efetuar o cálculo das tensões e ângulos de cada barra, considerando faixas de

demandas não treinadas e foi realizada a inicialização de um FC-NR. Para testes do sistema de 11 barras, foi escolhida uma barra específica do sistema e valores das potências reativas de geração e de carga para o processo de treinamento e de prova foram situados em um intervalo que promovesse a não convergência de um FC-NR. Esta formulação pode ser repetida para qualquer barra do sistema, apenas sendo necessário ajustar os valores do intervalo de treinamento e de prova para promover problemas de convergência do sistema para serem usadas nos testes e validação.

No processo de treinamento foram consideradas variações da potência reativa de geração e de carga da barra 8, para análise, situadas no intervalo [20,0 135,2] Mvar. Para os valores fora deste intervalo o FC-NR-CPO não apresentou solução, e estes casos foram desconsiderados na análise.

O número de neurônios da camada oculta também foi determinado dinamicamente através de testes e comparações dos erros dos dados de prova durante o processo de treinamento contínuo, entre o FC-NR-CPO e o FC-RNA-CPO, onde foi variada a composição dos neurônios da camada oculta de forma dinâmica, e armazenadas as RNA-CPOs que apresentaram o menor erro de simulação.

A quantidade de neurônios da camada oculta e da camada de saída utilizada para cada RNA-CPO envolvida no FC-RNA-CPO para o sistema de 11 barras está na Tabela 4.3.

Tabela 4.3: Dimensões das camadas e neurônios

Sistema	Neurônios Camada Oculta	Neurônios Camada de Saída
11 Barras	05/06	1

O primeiro caso utilizado para testes foi variar a **potência reativa de geração** de uma barra. Foram feitos vários testes com potências reativas de geração de diversas barras e para representar os resultados foi escolhida a barra 8 do sistema. Os erros máximos absolutos e médios absolutos de treinamento e prova apresentados para os valores da tensão e ângulo de fase, a comparação dos resultados obtidos pelo FC-RNA-CPO com o FC-NR-CPO para o sistema de 11 barras está representada na Tabelas 4.4.

Tabela 4.4: FC-RNA-CPO e FC-NR-CPO para variação de potência reativa de geração da barra 8

Sistema	Erros Absolutos de Treinamento		Erros Absolutos de Prova	
	Máximo	Médio	Máximo	Médio
<b>11 barras</b>				
$V$ (pu)	1,6759e-004	9,9464e-006	9,8509e-004	1,1552e-005
$\theta$ (rad)	2,7036e-004	7,9365e-006	8,9692e-004	8,7474e-006

O segundo caso utilizado para testes foi variar a **potência reativa de carga** de uma barra. Foram feitos vários testes com potências reativas de carga de diversas barras também como no primeiro caso, e para representar os resultados foi escolhida a barra 8 do sistema. Os erros máximos absolutos e médios absolutos de treinamento e prova apresentados para os valores da tensão e ângulo de fase, comparando os resultados obtidos pelo o FC-RNA-CPO com o FC-NR-CPO para o sistema de 11 barras estão representados na Tabelas 4.5.

Tabela 4.5: FC-RNA-CPO e FC-NR-CPO para variação de potência reativa de carga da barra 8

Sistema	Erros Absolutos de Treinamento		Erros Absolutos de Prova	
	Máximo	Médio	Máximo	Médio
<b>11 barras</b>				
$V$ (pu)	3,3595e-004	1,6934e-005	8,8402e-004	1,9317e-005
$\theta$ (rad)	5,0308e-004	1,3833e-005	6,7334e-004	1,4388e-005

Foram realizados testes com RNA-CPO que apresentaram taxas de erro maiores do que esta obtida, e não afetaram o resultado final. O que aconteceu é o que o número de iterações aumentou.

A terceira etapa após a aprovação dos resultados obtidos pelo FC-RNA-CPO foi inicializar um FC-NR com resultados obtidos do FC-RNA-CPO, chamado de FC-NR-RNA-I. Nestes testes, compararam-se os resultados das tensões e ângulos obtidos pelo FC-NR-RNA-I com o FC-NR-CPO. A Tabela 4.6 mostra os resultados dos erros máximos absolutos e médios absolutos das tensões e ângulos obtidos com o método FC-NR-RNA-I iniciado com os valores de tensão e ângulo a partir da RNA comparados com o FC-NR-CPO.

Tabela 4.6: FC-NR-RNA-I e FC-NR-CPO para variação de potência reativa de geração e de carga da barra 8

Sistema	Erros Absolutos das Tensões (pu)		Erros Absolutos dos Ângulos(rad)	
	Máximo	Médio	Máximo	Médio
11 barras				
Geração	1,9454e-004	1,6057e-005	1,1977e-004	5,1635e-006
Carga	1,9223e-004	1,8997e-005	1,2034e-004	7,9403e-006

O FC-NR convencional apresenta problema de convergência para alguns valores de  $Q_8$ , mas a faixa de solução para FC-NR-RNA-I é mais abrangente, e nas simulações do método de FC-NR sem ser iniciado pela RNA ocorreram muitas situações de não convergência. As Figuras 4.4, 4.5, 4.6 e 4.7 ilustram esta situação. Nas figuras 4.4, 4.5, 4.6 e 4.7 os valores correspondentes ao FC-RNA-CPO estão muito próximos do FC-NR-RNA-I, conforme os erros absolutos apresentados anteriormente pela tabela 4.4, e isto fez com que as curvas ficassem praticamente sobrepostas. As diferenças de valores entre o FC-NR-CPO e o FC-NR-RNA-I são muito pequenos conforme ilustrou anteriormente a Tabela 4.5




Figura 4.4: Tensões e Variação da Potência Reativa de Geração da Barra 8.

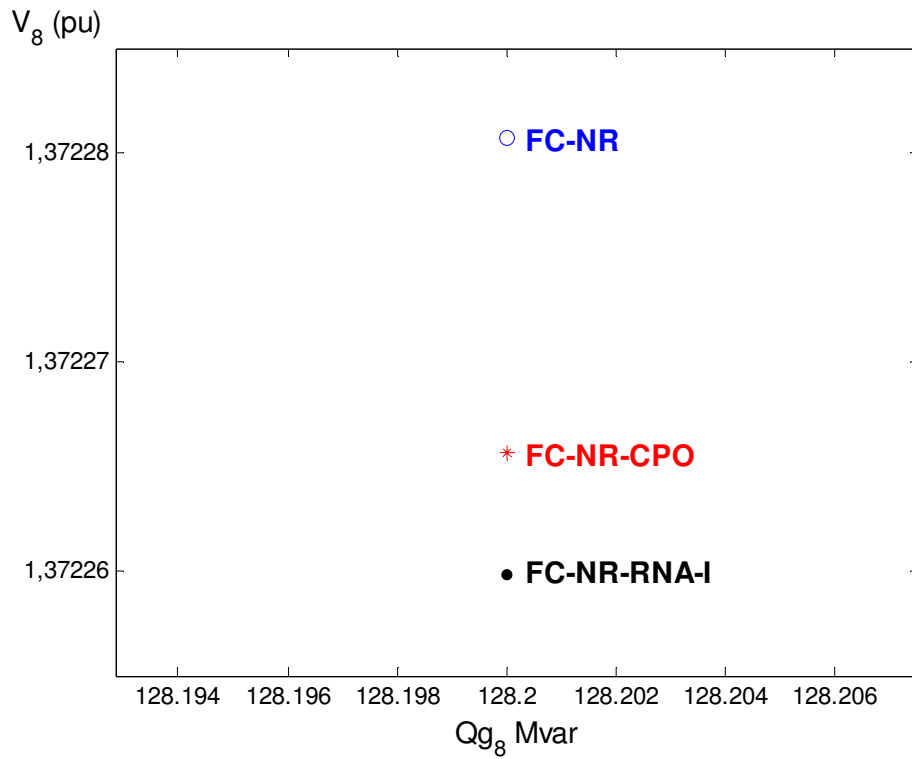


Figura 4.5: Zoom de um ponto de Tensão e Variação da Potência Reativa de Geração da Barra 8.




Figura 4.6: Ângulos da Barra 8 e Variação da Potência Reativa de Geração da Barra 8.

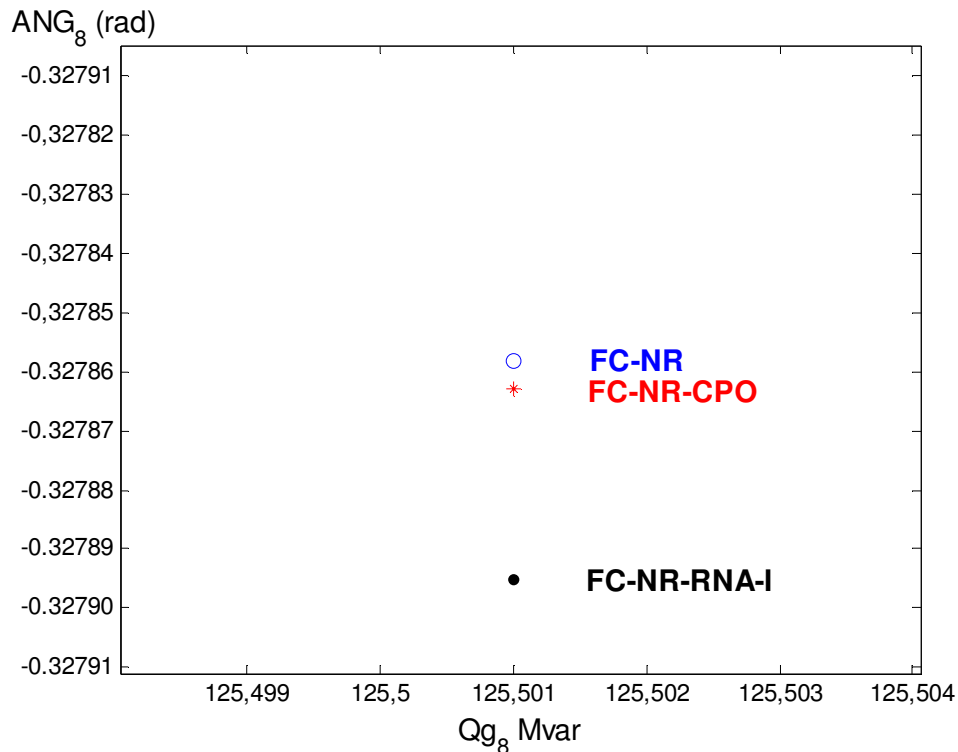


Figura 4.7: Zoom de um ponto de Ângulo e Variação da Potência Reativa de Geração da Barra 8.

Para as variações da **potência reativa de carga da barra 8** o FC-NR não apresentou nenhuma situação de convergência.

O número máximo de iterações do FC-NR-RNA-I iniciado pelos valores obtidos pela RNA, considerando o caso de variação da potência reativa de geração foi de uma iteração em todos os casos, somente ocorreu um caso com quatro iterações. Para o caso da potência reativa de carga o número máximo de iterações foi igual a dois.

## 4.5 Testes Realizados para o Sistema IEEE057

Um outro teste realizado foi a inicialização de um FC-NR com RNA para o sistema IEEE057 considerando as contingências e os valores de demanda da seção 3.5. Os resultados dos erros máximos e médios das tensões e ângulos obtidos com o FC-NR-RNA-I iniciado com os



valores de tensão e ângulo a partir da RNA comparados com o FC-NR para o sistema IEEE057, encontram-se na Tabela 4.7, e foram considerados bons.

Tabela 4.7: Erros de FC-NR-RNA-I e FC-NR

Sistema	Treinamento		Simulação	
	Máximo	Média	Máximo	Média
IEEE057				
$V$ (pu)	3,9983e-004	2,1982e-005	5,2901e-004	2,4572e-005
$\theta$ (rad)	1,1088e-004	4,3219e-006	2,4317e-004	5,0111e-006

Dos 743 casos de simulações consideradas para treinamento, 719 atingiram a convergência com uma iteração apenas e 24 com duas iterações, e dos 864 considerados para prova, 814 atingiram a convergência com uma iteração apenas e 50 com duas iterações. Estes testes realizados, independentemente dos aspectos de convergência relatados para os testes do sistema de 11 barras, foram interessantes sob o aspecto de redução do número de iterações do FC-NR quando este é inicializado por resultados obtidos através de um FC-RNA.

# Capítulo 5

## Equivalentes Externos

Equivalentes externos podem ser usados em estudos de planejamento e da operação de sistemas de energia elétrica, onde parte das redes elétricas pode ser representada pelos equivalentes, visando a redução das dimensões dos problemas de análise do fluxo de carga, e assim reduzindo o tempo computacional [28].

Os equivalentes existem para substituir parte da rede por uma rede simplificada de menor porte, de forma que seu comportamento seja o mais próximo possível da rede original. O objetivo do equivalente é simular as reações da rede externa quando ocorrem alterações na área de interesse [28].

Uma outra consideração a respeito dos equivalentes é a situação das aplicações ligadas à supervisão e ao controle em tempo real. Geralmente, têm-se informações atualizadas somente da parte monitorada da rede, e assim as partes não monitoradas podem ser representadas pelos equivalentes.

Em sistemas de grande porte tem-se a divisão da rede por empresas, a rede é interligada e, portanto as análises relativas à rede elétrica geralmente demandam um esforço grande de tempo. Assim, as áreas de interesse em geral são internas a uma empresa e no máximo partes da rede de empresas vizinhas, geralmente as barras de ligação e seus elementos de redes mais próximos. Se for considerada a representação relacionada a este interesse, teríamos uma rede reduzida em relação ao sistema completo.

A idéia da rede reduzida é diminuir o esforço computacional de cálculo de: fluxo de carga que é amplamente usado nas análises de contingências de linhas de transmissão; a alocação ótima de capacitores; o planejamento de expansão de redes de transmissão e análise de curto-circuito. A idéia básica é obter o estado da rede completa, obter a rede reduzida (equivalente), e realizar as análises [28].

Se for considerada a representação relacionada a este interesse, tem-se uma rede reduzida em relação ao sistema completo, conforme Figura 5.1.




Figura 5.1: Representação das áreas interna e externa de um sistema de potência.

Existem vários modelos de cálculo de equivalentes propostos na literatura e que são bem conhecidos: Ward (modelo linear e não linear), Ward com retenção de barras PV, Ward estendido, fluxo de carga não reduzido e REI [29].

Neste trabalho é proposto método de utilização de RNAs para o cálculo de equivalentes. Inicialmente um FC-RNA calcula os valores de  $V$  e  $\theta$  das barras de fronteira, e depois estes valores são devidamente substituídos nos dados de um FC-NR, com a modificação do tipo das barras de fronteira para  $V\theta$ .

## 5.1 Equivalentes usando RNA

Para obter o equivalente, usa-se os conceitos do FC-RNA, e neste caso específico treina-se somente as RNAs correspondentes às barras de fronteira considerando os dados de rede interna ou de interesse, resultando em uma RNA de menor dimensão.

O primeiro passo do cálculo do equivalentes consiste em obter as RNA que calculam  $V$  e  $\theta$  das barras de fronteira. A segunda parte refere-se à redução do sistema, eliminando qualquer ligação entre o sistema interno e a fronteira com o sistema externo, e sem realizar nenhum cálculo de redução de circuitos. A terceira parte refere-se a fixação das barras de fronteira como tipo  $V\theta$  no sistema reduzido. Posteriormente executa-se o FC-NR convencional tomando os valores de  $V$  e  $\theta$  obtidos pela RNA e substituindo dinamicamente no sistema reduzido. A Figura 5.2 representa o esquema de equivalentes externos utilizando RNA.




Figura 5.2: Esquema do equivalente com RNA.

Os resultados das tensões e ângulos calculados a partir da rede reduzida com equivalente RNA foram comparados com os valores obtidos pelo FC da rede completa, e considerados muito bons. Também se comparou com os resultados obtidos a partir da rede reduzida com o equivalente Ward estendido, e os resultados do equivalente neural apresentaram erros menores. O controle dos erros foi realizado baseando-se nas seguintes equações:

$$e_v^{ij} = \left| V_{NR}^{ij} - V_{NR-RNAeq}^{ij} \right| \quad (5.1)$$

$$e_\theta^{ij} = \left| \theta_{NR}^{ij} - \theta_{NR-WEeq}^{ij} \right| \quad (5.2)$$

$$e_v^{\max} = \max \left\{ e_v^{ij} \right\} \quad (5.3)$$

$$e_\theta^{\max} = \max \left\{ e_\theta^{ij} \right\} \quad (5.4)$$

$$e_v^{av} = \frac{1}{n_b \cdot n_{if}} \sum_{i=1}^{nb} \sum_j^{nif} e_v^{ij} \quad (5.5)$$

$$e_\theta^{av} = \frac{1}{n_b \cdot n_{if}} \sum_{i=1}^{nb} \sum_j^{nif} e_\theta^{ij} \quad (5.6)$$

onde  $i, j, nb, nif, V_{NR-RNAeq}^{ij}, V_{NR}^{ij}, \theta_{NR-WEeq}^{ij}, \theta_{NR}^{ij}, e_v^{\max}, e_v^{av}, e_\theta^{\max}, e_\theta^{av}$  correspondem respectivamente ao número da barra, número do caso de simulação, número total de barras da rede reduzida, número total de casos de simulação de treinamento ou prova, magnitude da tensão

calculada pelo FC-NR com equivalente RNA para a rede reduzida, magnitude da tensão calculada pelo FC-NR para a rede completa, ângulos de fase calculados pelo FC-NR com equivalente RNA para a rede reduzida, ângulos de fase calculados pelo FC-NR para a rede completa, erro máximo das tensões, erro médio das tensões, erro máximo dos ângulos, erro médio dos ângulos.

## 5.2 Testes Realizados para o Sistema IEEE030

Testes foram realizados utilizando o sistema IEEE030 barras, escolhendo as barras 4, 6 e 28 como sendo de fronteira conforme figura 5.3.




Figura 5.3: Regiões interna e externa do sistema IEEE030 com barras de fronteira 4, 6 e 28

Tabela 5.1: Sistema IEEE030 – Equivalente

Barra	Tipo	Situação	Barra	Tipo	Situação
1	Slack	Interna	16	PQ	Externa
2	PV	Interna	17	PQ	Externa
3	PQ	Interna	18	PQ	Externa
4	PQ	Fronteira	19	PQ	Externa
5	PV	Interna	20	PQ	Externa
6	PQ	Fronteira	21	PQ	Externa
7	PQ	Interna	22	PQ	Externa
8	PV	Externa	23	PQ	Externa
9	PQ	Externa	24	PQ	Externa
10	PQ	Externa	25	PQ	Externa
11	PQ	Externa	26	PQ	Externa
12	PQ	Externa	27	PQ	Externa
13	PV	Externa	28	PQ	Fronteira
14	PQ	Externa	29	PQ	Externa
15	PQ	Externa	30	PQ	Externa

Foram estipuladas faixas de demanda idênticas às utilizadas no treinamento e prova das redes RNA, e foram considerados: o caso base, contingência de ramos, saídas de carga, geração, e de elementos *shunts* para obtenção do equivalente RNA. Para a rede reduzida foram aplicados os mesmos critérios e foi executado um FC-NR, usando informações do equivalente RNA.

Os resultados das tensões e ângulos calculados a partir da rede reduzida com equivalente RNA foram comparados com os valores obtidos pelo FC-NR da rede completa, e considerados muito bons. Também se comparou com os resultados obtidos a partir da rede reduzida com o equivalente Ward estendido.

Os resultados dos erros máximos absolutos e médios absolutos das tensões e ângulos de treinamento e prova, obtidos com o FC-NR com RNA-eq comparados com o FC-NR completo para o sistema IEEE030, encontram-se na Tabela 5.2.

Tabela 5.2: Erros de FC-NR e RNA-eq

Sistema	Dados Treinamento		Dados Prova	
	Erro Máximo	Erro Médio	Erro Máximo	Erro Médio
IEEE030				
V (pu)	4,0064e-004	4,6602e-006	4,3070e-004	4,8667e-006
$\theta$ (rad)	2,8041e-004	5,6768e-006	2,2330e-004	5,8748e-006

Os resultados dos erros máximos e médios das tensões e ângulos de treinamento e prova, obtidos com o FC-NR com WE-eq comparados com o FC-NR completo para o sistema IEEE030, encontram-se na Tabelas 5.3.

Tabela 5.3: Erros de FC-NR e WE-eq

Sistema	Dados Treinados		Dados Prova	
	Erro Máximo	Erro Médio	Erro Máximo	Erro Médio
IEEE030				
V (pu)	0,0830	8,7779e-004	0,0780	8,4849e-004
$\theta$ (rad)	0,2537	0,0103	0,2380	0,0099

Os resultados obtidos com o FC-NR utilizando equivalente neural RNA-eq mostraram-se com erros menores que o FC-NR com equivalente WE-eq, para o sistema IEEE030.

### 5.3 Testes Adicionais Realizados para o Sistema IEEE030

Foram realizados testes adicionais para o sistema IEEE030, e escolhidas novamente como fronteiras as barras 4, 6 e 28. Foram estipuladas faixas de demanda idênticas às utilizadas no treinamento e prova das redes RNA, e foram considerados: o caso base, contingência de ramos, saídas de carga, geração, e de elementos *shunts*, e o controle de limites de tensão das barras PV, para obtenção do equivalente RNA. A diferença deste teste com relação ao teste da seção anterior é justamente o controle de limites de tensão das barras PV.

Para a rede reduzida, foram aplicados os mesmos critérios e executado um FC-NR usando informações do RNA com controles, o RNA-CTRL-eq. Os resultados das tensões e ângulos calculados a partir da rede reduzida com equivalente RNA-CTRL-eq, foram comparados com os valores obtidos pelo FC da rede completa, e foram considerados piores em relação aos resultados obtidos da RNA-eq. A barra 5 foi a responsável por estes erros e pela elevação da média

Os resultados dos erros máximos absolutos e médios absolutos das tensões e ângulos, de treinamento e prova obtidos com o FC-NR com RNA-CTRL-eq comparados com o FC-NR completo para o sistema IEEE030, encontram-se na Tabela 5.4.

Tabela 5.4: Erros de FC-NR e RNA-CTRL-eq

Sistema	Dados Treinados		Dados Prova	
	Erro Máximo	Erro Médio	Erro Máximo	Erro Médio
IEEE030				
V (pu)	0,2338	0,0120	0,2152	0,0124
$\theta$ (rad)	0,0943	0,0023	0,0857	0,0022

A Figuras 5.3 e 5.4 retratam os erros máximos e os erros médios obtidos respectivamente para as tensões e ângulos do sistema reduzido. Os erros médios encontram-se em uma faixa aceitável, mas os erros máximos possuem valores altos.

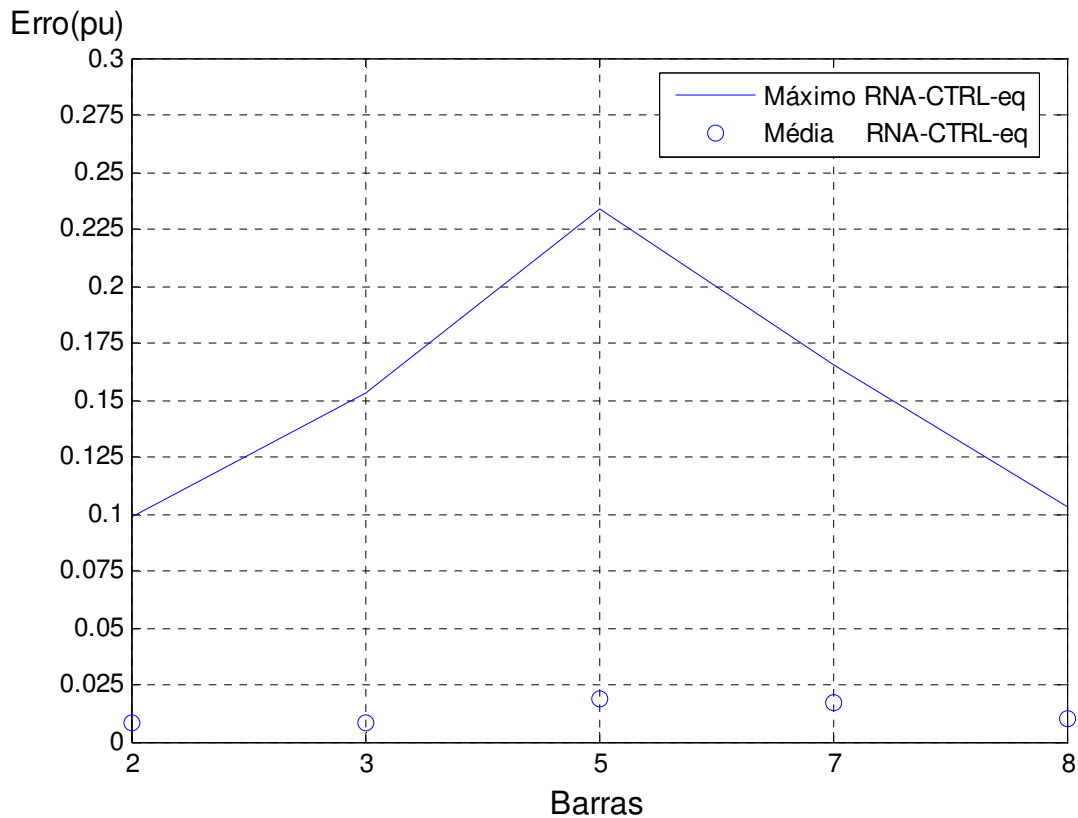


Figura 5.4: Erros máximos e erros médios das tensões em pu.



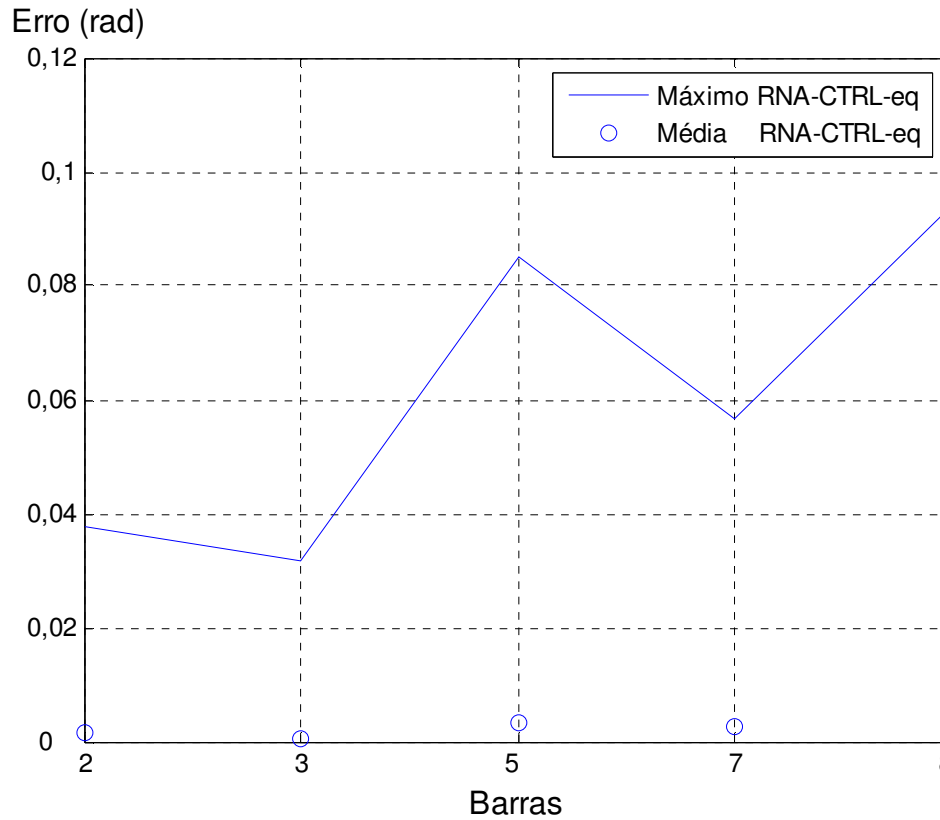


Figura 5.5: Erros máximos e erros médios dos ângulos em radianos.

Estes testes foram realizados inicialmente para verificação, mas necessitariam serem aprofundados nas questões dos limites e do padrão de reconhecimento da RNA, para o cálculo dos equivalentes com controle de limites de tensão das barras PV.

## 5.4 Testes Realizados para o Sistema IEEE057

Também foram feitos testes com o sistema IEEE057 barras, e dois casos foram utilizados nas simulações: I) barras de fronteira 4, 9, 11 e 38 representado pela Figura 5.6 e pela Tabela 5.5; II) barras de fronteira 11, 24 e 38 representado pela Figura 5.7 e pela Tabela 5.6.

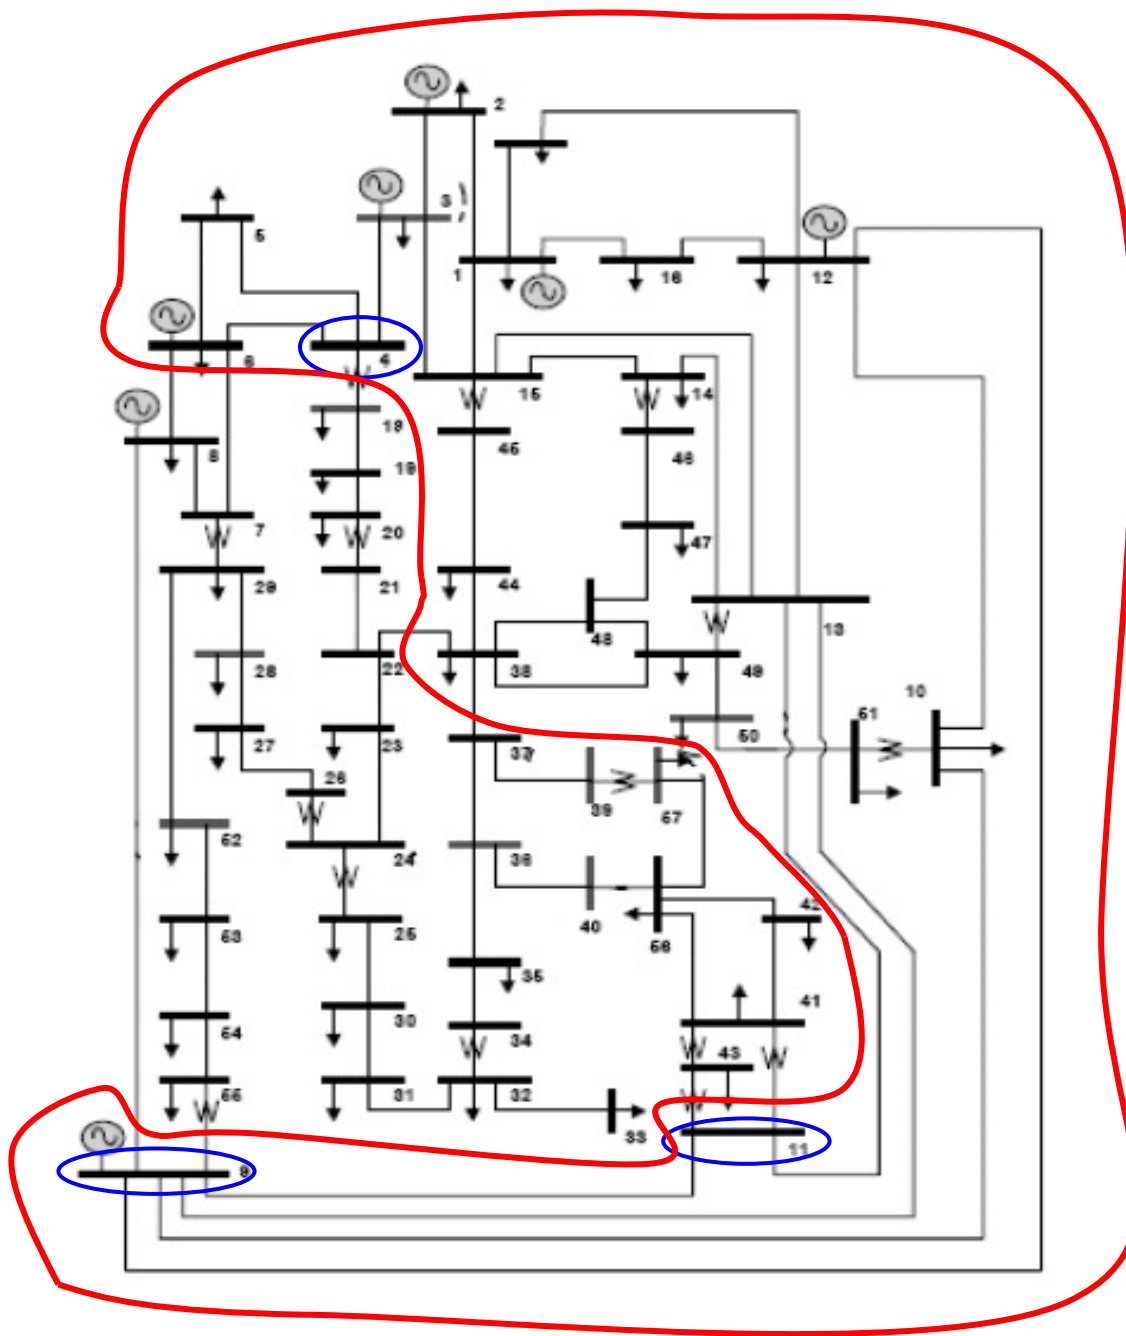


Figura 5.6: Regiões Internas e Externas do sistema IEEE057, caso I com barras de fronteira 4, 9, 11 e 38.

Tabela 5.5: Rede IEEE057 Equivalente - Caso I

<b>Barra</b>	<b>Tipo</b>	<b>Situação</b>	<b>Barra</b>	<b>Tipo</b>	<b>Situação</b>	<b>Barra</b>	<b>Tipo</b>	<b>Situação</b>
1	Slack	Interna	20	PQ	Externa	39	PQ	Externa
2	PV	Interna	21	PQ	Externa	40	PQ	Externa
3	PV	Interna	22	PQ	Externa	41	PQ	Externa
4	PQ	Fronteira	23	PQ	Externa	42	PQ	Externa
5	PQ	Externa	24	PQ	Externa	43	PQ	Externa
6	PV	Interna	25	PQ	Externa	44	PQ	Interna
7	PQ	Externa	26	PQ	Externa	45	PQ	Interna
8	PV	Externa	27	PQ	Externa	46	PQ	Interna
9	PV	Fronteira	28	PQ	Externa	47	PQ	Interna
10	PQ	Interna	29	PQ	Externa	48	PQ	Interna
11	PQ	Fronteira	30	PQ	Externa	49	PQ	Interna
12	PV	Interna	31	PQ	Externa	50	PQ	Interna
13	PQ	Interna	32	PQ	Externa	51	PQ	Interna
14	PQ	Interna	33	PQ	Externa	52	PQ	Externa
15	PQ	Interna	34	PQ	Externa	53	PQ	Externa
16	PQ	Interna	35	PQ	Externa	54	PQ	Externa
17	PQ	Interna	36	PQ	Externa	55	PQ	Externa
18	PQ	Externa	37	PQ	Externa	56	PQ	Externa
19	PQ	Externa	38	PQ	Fronteira	57	PQ	Externa

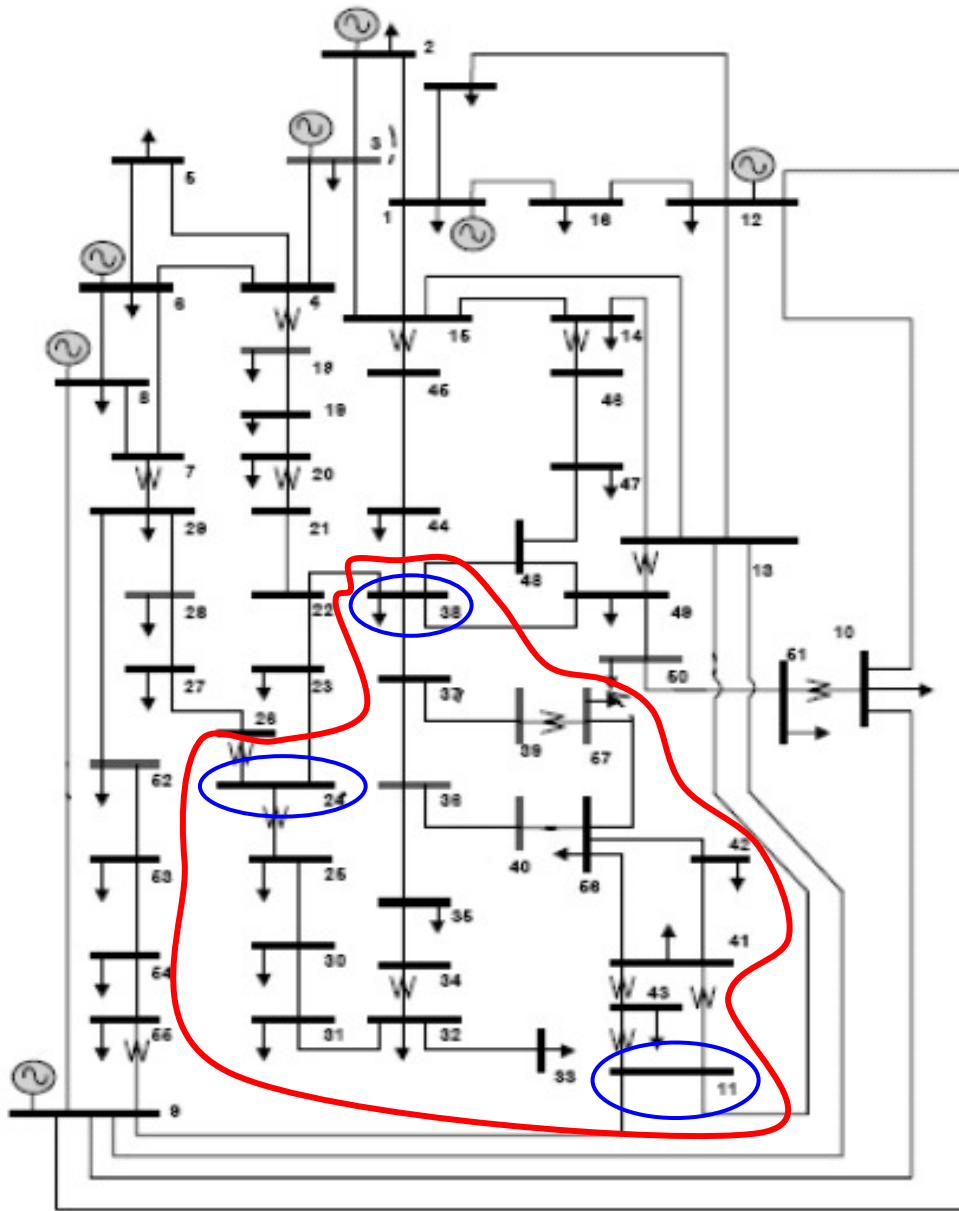


Figura 5.7: Regiões Internas e Externas do sistema IEEE057, caso II com barras de fronteira 11, 24 e 38.

Tabela 5.6: Rede IEEE057 Equivalente - Caso II

Barra	Tipo	Situação	Barra	Tipo	Situação	Barra	Tipo	Situação
1	Slack	Externa	20	PQ	Externa	39	PQ	Interna
2	PV	Externa	21	PQ	Externa	40	PQ	Interna
3	PV	Externa	22	PQ	Externa	41	PQ	Interna
4	PQ	Externa	23	PQ	Externa	42	PQ	Interna
5	PQ	Externa	24	PQ	Fronteira	43	PQ	Interna
6	PV	Externa	25	PQ	Interna	44	PQ	Externa
7	PQ	Externa	26	PQ	Externa	45	PQ	Externa
8	PV	Externa	27	PQ	Externa	46	PQ	Externa
9	PV	Externa	28	PQ	Externa	47	PQ	Externa
10	PQ	Externa	29	PQ	Externa	48	PQ	Externa
11	PQ	Fronteira	30	PQ	Interna	49	PQ	Externa
12	PV	Externa	31	PQ	Interna	50	PQ	Externa
13	PQ	Externa	32	PQ	Interna	51	PQ	Externa
14	PQ	Externa	33	PQ	Interna	52	PQ	Externa
15	PQ	Externa	34	PQ	Interna	53	PQ	Externa
16	PQ	Externa	35	PQ	Interna	54	PQ	Externa
17	PQ	Externa	36	PQ	Interna	55	PQ	Externa
18	PQ	Externa	37	PQ→ Slack	Interna	56	PQ	Interna
19	PQ	Externa	38	PQ	Fronteira	57	PQ	Interna

Para os testes realizados para comparação utilizando o equivalente Ward estendido para o caso II, a barra 37 foi adotada como slack. O critério adotado para escolher a barra 37 foi: tomar todos os valores das tensões de todas as barras internas e de fronteira, considerando todas as contingências e fazer a média por barra e depois fazer a diferença entre as tensões e a média respectiva por barra. A barra 37 foi escolhida porque apresentou o menor valor para esta diferença.

Foram estipuladas faixas de demanda idênticas às utilizadas no treinamento e prova das redes RNA, e foram considerados: o caso base, contingência de ramos, saídas de carga, geração, e de elementos *shunt*, para obtenção do equivalente RNA. Para a rede reduzida foram aplicados os mesmos critérios e foi executado um FC-NR, usando informações do equivalente RNA.

Os resultados das tensões e ângulos calculados a partir da rede reduzida com equivalente RNA foram comparados com os valores obtidos pelo FC-NR da rede completa, e considerados muito bons. Também se comparou com os resultados obtidos a partir da rede reduzida com o

equivalente Ward estendido, e os resultados do RNA-eq mostram-se com erros menores para os casos I e II.

Os resultados das tensões e ângulos calculados a partir da rede reduzida com RNA-eq, foram comparados com FC-NR para a rede completa.

Para o caso I, os resultados dos erros máximos absolutos e médios absolutos das tensões e ângulos, de treinamento e prova obtidos com o FC-NR com RNA-eq comparados com o FC-NR completo para o sistema IEEE057, encontram-se na Tabela 5.7.

Tabela 5.7: Erros de FC-NR e RNA-eq - caso I

Sistema	Erro Absoluto Treinamento		Erro Absoluto Prova	
	Máximo	Médio	Máximo	Médio
IEEE057				
V (pu)	3,7701e-004	2,4741e-005	5,5045e-004	2,8590e-005
$\theta$ (rad)	4,5519e-004	2,3885e-005	7,3217e-004	3,5070e-005

Para o caso II, os resultados dos erros máximos absolutos e médios absolutos das tensões e ângulos, de treinamento e prova obtidos com o FC-NR com RNA-eq comparados com o FC-NR completo para o sistema IEEE057, encontram-se na Tabelas 5.8.

Tabela 5.8: Erros de FC-NR e RNA-eq - caso II

Sistema	Erro Absoluto Treinamento		Erro Absoluto Prova	
	Máximo	Médio	Máximo	Médio
IEEE057				
V (pu)	4,2440e-004	6,1012e-005	9,6117e-004	7,4840e-005
$\theta$ (rad)	2,9894e-004	2,6603e-005	4,3951e-004	4,0411e-005

Outra comparação realizada foi entre tensões e ângulos calculados a partir da rede reduzida com equivalente Ward estendido, e as calculadas com o FC-NR para a rede completa.

Para o caso I, os resultados dos erros máximos e médios das tensões e ângulos, de treinamento e prova obtidos com o FC-NR e com WE-eq comparados com o FC-NR completo para o sistema IEEE057, encontram-se na Tabela 5.9.

Tabela 5.9: Erros de FC-NR e WE-eq - caso I

Sistema	Erro Absoluto Treinamento		Erro Absoluto Prova	
	Máximo	Médio	Máximo	Médio
IEEE057				
$V$ (pu)	0,1509	0,0287	0,1555	0,0288
$\theta$ (rad)	0,5164	0,0927	0,5421	0,0993

Para o caso II, os resultados dos erros máximos e médios das tensões e ângulos, de treinamento e prova, obtidos para o FC-NR com WE-eq comparados com o FC-NR completo para o sistema IEEE057, encontram-se na Tabelas 5.10.

Tabela 5.10: Erros de FC-NR e WE-eq C caso II

Sistema	Erro Absoluto Treinamento		Erro Absoluto Prova	
	Erro Máximo	Erro Médio	Erro Máximo	Erro Médio
IEEE057				
$V$ (pu)	0,2958	0,0289	0,2792	0,0298
$\theta$ (rad)	0,3522	0,0683	0,3588	0,0726

Os valores das tensões obtidas utilizando o equivalente neural RNA-eq e o equivalente Ward estendido WE-eq foram comparados com os valores obtidos pelo FC-NR completo para o caso I de testes. Estas diferenças estão na Figura 5.8 apresentando o valor máximo e a média do erro absoluto para cada barra.

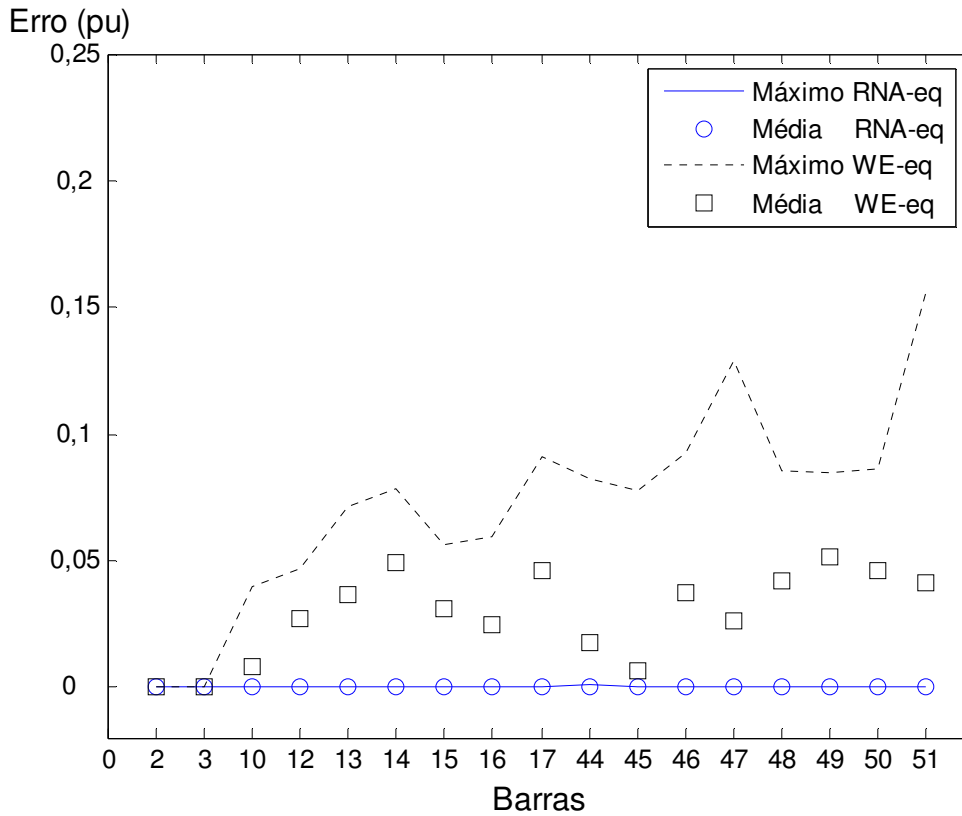


Figura 5.8: Erros máximos e erros médios tensões simulação – caso I.

Os valores dos ângulos obtidos pelo utilizando o equivalente neural RNA-eq e o equivalente Ward estendido WE-eq foram comparados com os valores obtidos pelo FC-NR completo para o caso I de testes. Estas diferenças estão na Figura 5.9 apresentando o valor máximo e a média do erro para cada barra.






Figura 5.9: Erros máximos e erros médios ângulos simulação – caso I.

Os valores das tensões obtidas utilizando o equivalente neural RNA-eq e o equivalente Ward estendido WE-eq foram comparados com os valores obtidos pelo FC-NR completo para o caso II de testes. Estas diferenças estão na Figura 5.10 apresentando o valor máximo e a média do erro absoluto para cada barra.




Figura 5.10: Erros máximos e erros médios tensões simulação – caso II.

Os valores dos ângulos obtidas utilizando o equivalente neural RNA-eq e o equivalente Ward estendido WE-eq foram comparados com os valores obtidos pelo FC-NR completo para o caso II de testes. Estas diferenças estão na Figura 5.11 apresentando o valor máximo e a média do erro para cada barra.

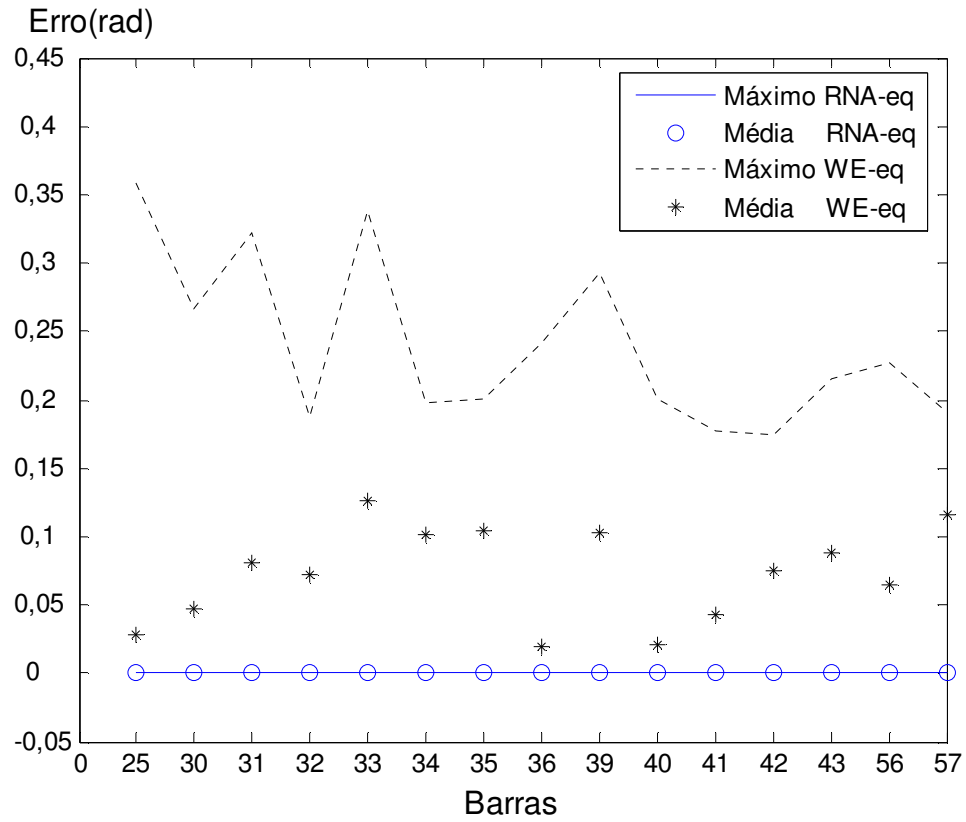


Figura 5.11: Erros máximos e erros médios ângulos simulação – caso II.

# Capítulo 6

## Conclusões

Neste trabalho, foi apresentada uma metodologia utilizando RNA para prover: **(a)** solução do fluxo de carga (FC); **(b)** solução do FC considerando controles e limites de tensão nas barras PV; **(c)** inicialização de um FC para sistemas mal condicionados; **(d)** inicialização de um FC-NR e **(e)** cálculo de equivalentes externos estáticos para sistemas de energia elétrica utilizando RNA.

Foi definida uma arquitetura de RNA visando minimizar a dimensão do problema e criar um padrão de modelagem de forma a reaproveitar as formulações de um problema para o outro considerando os itens acima.

Foram utilizados recursos de modelagem de RNA como normalização, simplificação, e adequação dos dados de entrada, correspondentes ao treinamento e à simulação.

Foi elaborada uma estratégia de treinamento e montagem dos dados para simulação de forma a obter erros que permitam a aceitação e resolução das proposições.

Foi proposto um esquema de controle eficiente para minimizar os erros de prova das tensões e ângulos.

A metodologia proposta de FC com e sem controles foi testada usando os sistemas de teste Ward-Hale de 6 barras, IEEE de 14, 30 e 57 barras [7], considerando o caso base e diversos casos de contingências simples. A inicialização das variáveis de estado usando uma RNA para a execução de um FC foi testada nos sistemas IEEE de 57 barras e no sistema de 11 barras, considerando as dificuldades de convergência do FC submetido a variações de geração e de carga. Para o cálculo de equivalentes externos estáticos usando RNA, foram testados o sistema IEEE de 30 barras, e o sistema IEEE de 57 barras.

Nos testes realizados, foi verificada a sensibilidade das RNA ao número de entradas e saídas, verificando em alguns casos a dificuldade de treiná-las de forma eficiente e rápida em função da dimensão do problema.

Foram construídas diversas arquiteturas de RNA e formação dos dados de entrada e saída visando a simplificação do problema, e a sua adequação pensando em economia de recursos computacionais sem prejudicar os resultados.

As dimensões dos problemas em sistemas de potência e o seu equacionamento são complexos e esta complexidade foi transferida para os estudos de modelagem do problema utilizando RNA.

Após os esforços realizados na modelagem, verificou-se a obtenção de bons resultados e algumas vantagens que podem ser obtidas após o treinamento das RNA, considerando que ao obter uma RNA eficiente ela pode ser decomposta para que seja realizado um cálculo matemático mais simples que o realizado em um fluxo de carga.

O processo mais caro em termos computacionais é o treinamento, e neste item foram concentrados os esforços dos testes e variações de alternativas.

A modelagem dos dados para o treinamento tem de ser cuidadosamente preparada, pois dela depende o sucesso das proposições e resultados obtidos. Técnicas de treinamento dinâmico foram usadas para obtenção da melhor configuração de neurônios, e o momento de interromper o treinamento para não perder a generalização da RNA para os dados não treinados.

As RNA obtidas foram todas armazenadas para uso futuro, produzindo uma biblioteca de RNA interessantes para os sistemas apresentados nos testes.

A RNA é sensível aos dados de entrada apesar de seus aspectos de generalização baseado no conhecimento adquirido no treinamento. Nos testes avaliou-se que talvez seja mais interessante em algumas situações criar uma espécie de cluster de RNA. Como exemplo disto, tem-se a divisão de RNA por barras, e no caso da consideração de controles e limites uma RNA específica para esta situação, e ainda um conjunto de RNA por sistema testado, considerando o cenário das demandas e contingências apresentadas.

Não foram realizados testes com sistemas maiores do que IEEE057, mas outras redes de tamanhos maiores poderiam ser treinadas utilizando os mesmos métodos apresentados anteriormente, e foi avaliada a possibilidade de enriquecer estes testes combinando as proposições variadas apresentadas como o uso de equivalentes para redução das dimensões das redes, e utilização de mais recursos de memória das máquinas, pois os testes foram limitados a máquinas com 1 Gb de memória RAM.

As contingências múltiplas não foram analisadas neste trabalho, mas poderiam ser modeladas e testadas considerando as mesmas técnicas, mas com RNA diferentes, podendo utilizar os resultados obtidos com as RNA atuais como ponto de partida.

As faixas de demandas utilizadas apresentam-se como um exemplo para testes das RNAs, mas caso seja necessário utilizar faixas diferentes, as RNAs poderiam ser re-treinadas com faixas distintas mas recomenda-se utilizar como ponto de partida as RNAs já armazenadas.

Uma vez obtida uma RNA para cálculo de uma determinada grandeza, para obter seu valor em uma simulação, basta apenas realizar um cálculo algébrico simples utilizando pesos e coeficientes para obter a saída, que comparada aos métodos numéricos é bem mais simples, pois não existem iterações e tampouco problemas de convergência, pois a rede já foi treinada. A parte mais complexa é referente ao treinamento e esta pode ser comparada em termos de complexidade com os métodos numéricos, pois se podem usar os mesmos recursos computacionais para obter um modelo de RNA para aproximação do FC com bons resultados.

Os resultados obtidos mostraram um bom desempenho das RNA para resolver a maioria dos casos analisados, podendo a RNA ser utilizada em casos em tempo real e em modo de estudo.

# Apêndice I

Como atividade complementar ao trabalho realizado foram feitos alguns estudos sobre outros controles e limites e sua ação sobre o fluxo de carga. Não foram realizados testes com estes controles e limites, mas apenas uma análise genérica de suas influências na modelagem do problema com RNA.

A inclusão de controles e limites afeta diretamente o FC, e no trabalho realizado, utiliza-se o mesmo para montar os dados e a arquitetura da RNA, ou seja, dados de entrada e dados de saída de treinamento e de prova para validar a solução e a utilização destes dados pelo conjunto das RNA.

Toda alteração que afeta os dados de entrada e as saídas afeta o modelo das RNA utilizadas, e também o controle de montagem de dados de prova e treinamento e a própria arquitetura das RNA.

Nos estudos apresentados foram mostrados os trabalhos e testes realizados com os limites de injeção de potência reativa em barras PV. A seguir será mostrado como se pode utilizar a metodologia anteriormente apresentada para tratar de outros controles e limites, que não foram incluídos nestes estudos.

## Tipos de Controles e Limites

Os controles e limites de um FC podem ser representados do seguinte modo:

- Através da classificação por tipos de barras, e conseqüentemente o seu agrupamento nos grupos de equações correspondentes aos subsistemas 1 representado pelas equações de potência ativa e reativa das barras, com dimensão  $2NPQ+NPV$ , de onde se obtém as variáveis de estado, e subsequentemente o subsistema 2, com dimensão  $NPV+2$ , onde usando os resultados das variáveis de estado, calcula-se as potências reativas das barras PV e de referência e a potência ativa da barra de referência.

- Mecanismos de ajuste dos controles executados alternadamente na solução das equações do subsistema 1 do fluxo de carga.
- Incorporação ou substituição de equações e variáveis no subsistema 1 do fluxo de carga.

A implementação de controles e limites deixa o fluxo de carga mais complexo e também pode interferir nos tempos de execução e na convergência da solução. O fluxo de carga padrão usado seria adaptado para funcionar com todos os controles mediante parametrização, caso seja requerido um controle específico, o fluxo de carga deveria estar preparado para tratá-lo.

A seguir são apresentadas algumas análises sobre o FC, controles e limites e as RNA.

## Transformadores em Fase e Controle Automático de Tap

Os transformadores com controle automático de *tap* podem ser usados na regulação da magnitude das tensões nodais.

Seria necessário alterar o fluxo de carga com controles para contemplar esta restrição, e acrescentar saídas *tap* no cálculo das variáveis do subsistema 1. A informação do *tap* está presente nos elementos da diagonal das matrizes G e B utilizadas nos dados de estrada e fornecida pelo fluxo de carga. Esta inclusão de limites alteraria a dimensão dos dados de saída da rede neural, que faz o cálculo da parte com controles, baseado na informação do número de transformadores *tap* (nt). Durante a contingência dos ramos, deverá ser criado um mecanismo para retirar a influência do *tap* da linha que foi retirada, na composição dos elementos da diagonal das matrizes G e B. O restante seria modelado similarmente. Somente deveria ser considerado o cálculo dos *taps* como variáveis, e que o FC também deve estar preparado para fazer este cálculo, conforme mostra a Figura 7.1.






Figura 7.1: RNA e controle de TAP.

## Transformadores Defasadores com Controle Automático de Fase

Estes transformadores são usados para regular o fluxo de potência ativa nos ramos onde são inseridos. Para obter o estado de um sistema utilizando este controle, seria necessário alterar o fluxo de carga para contemplar esta restrição, e acrescentar saídas do defasador no cálculo das variáveis do subsistema 1. A informação do defasador está presente nos elementos da diagonal das matrizes G e B utilizadas nos dados de estrada e fornecida pelo fluxo de carga.

Esta inclusão de limites alteraria a dimensão dos dados de saída da RNA, que faz o cálculo da parte com controles, baseado na informação do número de transformadores defasadores (nd).

Durante a contingência dos ramos, deverá ser criado um mecanismo para retirar a influência do defasador da linha que foi retirada, na composição dos elementos da diagonal das matrizes G e B.

Para o restante somente deveria ser considerado o cálculo dos defasadores como variáveis, e que o FC também deve estar preparado para fazer este cálculo. A Figura 7.2 mostra o esquema geral a ser utilizado.

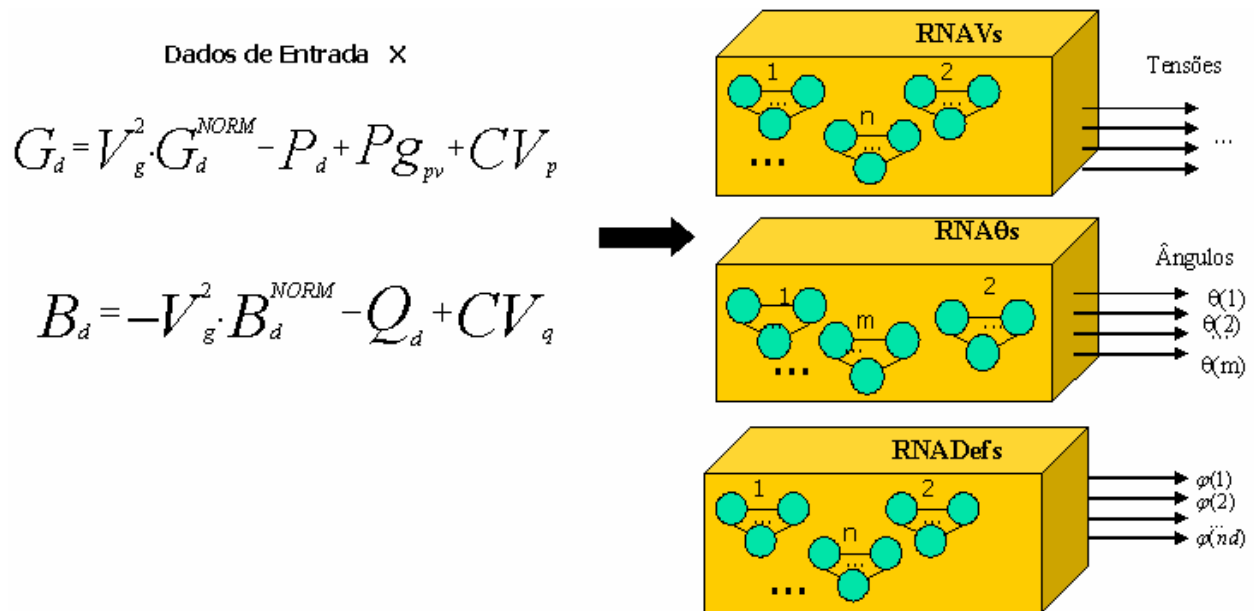


Figura 7.2: RNA e controle de transformadores defasadores.

## Controle de Intercâmbio entre Áreas

Controla o intercâmbio de potência ativa entre várias áreas, e considerando que um sistema possui um número de áreas ( $na$ ) e serão controlados  $na-1$  intercâmbios.

Para considerar mais áreas seria necessário alterar o FC com controles para contemplar esta restrição, e acrescentar as saídas de intercâmbio no cálculo das variáveis do subsistema 1. Esta informação do fluxo altera a matriz Jacobiana.

Esta inclusão do controle dos fluxos alteraria a dimensão dos dados de saída RNA, que faz o cálculo da parte com controles, baseado na informação do número de áreas de intercâmbio ( $na$ ).

O fluxo de carga deveria ser cuidadosamente elaborado, pois a parte referente ao controle entre áreas incluída na matriz jacobiana costuma apresentar zeros na diagonal, desta forma teria um tratamento específico das equações para isto, pois do contrário o sistema não apresentaria soluções. A figura 7.3 ilustra este modelo.




Figura 7.3: RNA e controle de intercâmbio entre áreas.

## Controle de Tensão em Barras Remotas

Este controle pode ser executado tanto por transformadores quanto por injeção de reativos. O primeiro caso já foi mencionado anteriormente.

O controle de tensão por injeção de reativos é diferente do controle de tensão das barras através da injeção de reativos para controlar a tensão da própria barra.

Considerando a barra de controle como do tipo P, será alterado o equacionamento das variáveis de saída de acordo com o tipo de barra, e a dimensão do problema será alterada, o subsistema 1 de equações do fluxo de carga será alterado.

Esta inclusão do controle dos fluxos também alteraria a dimensão dos dados de saída da RNA, que faz o cálculo da parte com controles, baseado na informação do tipo de barras. A Figura 7.4 mostra o esquema geral neste caso.




Figura 7.4: RNA e controle de tensão em barras remotas.

# Apêndice II – Arquivos dos Sistemas

## WARD-HALE 6 BARRAS

```

% Dados das barras
% 3 - slack ; 2 - PV ; 0 - PQ
%
% Número Tipo V(pu) Âng(g) Pg(MW) Qg(MVar) Pc(MW) Qc(MVar) bshk(MVar) Qmin Qmax
barras = [
1 3 1.050 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
2 2 1.100 0.0 50.1 0.0 0.0 0.0 0.0 -3.0 25.0
3 0 1.000 0.0 0.0 0.0 55.0 13.0 0.0 0.0 0.0
4 0 1.000 0.0 0.0 0.0 0.0 0.0 5.0 0.0 0.0
5 0 1.000 0.0 0.0 0.0 30.0 18.0 0.0 0.0 0.0
6 0 1.000 0.0 0.0 0.0 50.0 5.0 5.0 0.0 0.0
];

% Dados dos ramos
% bsh - carregamento total
%
% De Para r(pu) x(pu) bsh(pu) tap status
ramos = [
1 6 0.123 0.518 0.000 0.000 1
1 4 0.080 0.370 0.000 0.000 1
4 6 0.097 0.407 0.000 0.000 1
6 5 0.00001 0.300 0.000 1.025 1
5 2 0.282 0.640 0.000 0.000 1
2 3 0.723 1.050 0.000 0.000 1
4 3 0.00001 0.133 0.000 1.000 1
];

```




Figura 8.1: Sistema Ward-Hale 6 Barras

## Sistema 11 Barras

```

                                Rede do Scudder modificada (*)
PARAMETER DATA ( ipv - iout - modetr - itr )
BUS DATA
1 Barra 1  0 0.0000 0.00  0.00  0.00 400.00  87.00 1.0000 0.00 0.00 0.0000 0.0000
2 Barra 2  0 0.0000 0.00  0.00  0.00 500.00 165.00 1.0000 0.00 0.00 0.0000 0.0000
3 Barra 3  0 0.0000 0.00  75.00  0.00  0.00  42.00 1.0000 0.00 0.00 0.0000 0.0000
4 Barra 4  0 0.0000 0.00  0.00  0.00  25.00  81.00 1.0000 0.00 0.00 0.0000 0.0000
5 Barra 5  0 0.0000 0.00  0.00  0.00  0.00  0.00 1.0000 0.00 0.00 0.0000 0.0000
6 Barra 6  0 0.0000 0.00 250.00 11.00  0.00  0.00 1.0000 0.00 0.00 0.0000 0.0000
7 Barra 7  0 0.0000 0.00 200.00 42.00  0.00  0.00 1.0000 0.00 0.00 0.0000 0.0000
8 Barra 8  0 0.0000 0.00 250.00  0.00  0.00 123.00 1.0000 0.00 0.00 0.0000 0.0000
9 Barra 9  0 0.0000 0.00 175.00  3.00  0.00  0.00 1.0000 0.00 0.00 0.0000 0.0000
10 Barra 10 0 0.0000 0.00 375.00 59.00  0.00  0.00 1.0000 0.00 0.00 0.0000 0.0000
11 Barra 11 3 1.0400 0.00  0.00  0.00  0.00  0.00 1.0400 0.00 0.00 0.0000 0.0000
-999
BRANCH DATA
1  6  1 0 0.004000 0.080000 0.35000 999.0
2  7  1 0 0.000000 0.050000 0.00000 999.0
3  9  1 0 0.005000 0.100000 0.00000 999.0
4 10  1 0 0.003000 0.050000 0.02000 999.0
5  6  1 0 0.001000 0.027000 0.21400 999.0
5  8  1 0 0.000800 0.033000 0.18100 999.0
5 10  1 0 0.005000 0.100000 0.30000 999.0
5 11  1 0 0.002000 0.100000 0.40000 999.0
6  8  1 0 0.000220 0.005000 0.02200 999.0
7  8  1 0 0.003000 0.050000 0.14000 999.0
8  9  1 0 0.002300 0.030800 0.11220 999.0
9 10  1 0 0.001200 0.032000 0.12840 999.0
-999

```

-----  
 (\*) Os dados estao no relatorio:

Step size optimization in a polar Newton power Flow  
 J.M. Scudder

Scudder foi orientado do Alvarado quando fez este relatorio.

A potencia reativa na barra 8 pode ser modificada, levando aos seguintes resultados:

- . Se  $Q \geq 123$  MVar  $\rightarrow$  FC Newton converge para tensoes altas e a barra slack consome reativos.
- . Se  $120 < Q < 123$  MVar  $\rightarrow$  FC diverge
- . Se  $101 < Q \leq 120$  MVar  $\rightarrow$  FC Newton converge para tensoes baixas e a barra slack fornece reativos
- . Se  $Q \leq 101$  MVar  $\rightarrow$  FC diverge.

Format follows paper :

"Common Format for Exchange of Solved Load Flow Data"  
 Working Group on a Common Format for Exchange of Solved  
 Load Flow Data  
 IEEE Transactions on PAS, PAS-92, no.6, pp.1916-25  
 Nov/Dec'1973




Figura 8.2: Sistema de 11 Barras Scudder

## IEEE 14 BARRAS

08/19/93 UW ARCHIVE

100.0 1962 W IEEE 14 Bus Test Case

BUS DATA FOLLOWS

14 ITEMS

1	Bus 1	HV	1	1	3	1.060	0.0	0.0	0.0	232.4	-16.9	0.0	1.060	0.0	0.0	0.0	0.0	0
2	Bus 2	HV	1	1	2	1.045	-4.98	21.7	12.7	40.0	42.4	0.0	1.045	50.0	-40.0	0.0	0.0	0
3	Bus 3	HV	1	1	2	1.010	-12.72	94.2	19.0	0.0	23.4	0.0	1.010	40.0	0.0	0.0	0.0	0
4	Bus 4	HV	1	1	0	1.019	-10.33	47.8	-3.9	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
5	Bus 5	HV	1	1	0	1.020	-8.78	7.6	1.6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
6	Bus 6	LV	1	1	2	1.070	-14.22	11.2	7.5	0.0	12.2	0.0	1.070	24.0	-6.0	0.0	0.0	0
7	Bus 7	ZV	1	1	0	1.062	-13.37	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
8	Bus 8	TV	1	1	2	1.090	-13.36	0.0	0.0	0.0	17.4	0.0	1.090	24.0	-6.0	0.0	0.0	0
9	Bus 9	LV	1	1	0	1.056	-14.94	29.5	16.6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.19	0
10	Bus 10	LV	1	1	0	1.051	-15.10	9.0	5.8	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
11	Bus 11	LV	1	1	0	1.057	-14.79	3.5	1.8	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
12	Bus 12	LV	1	1	0	1.055	-15.07	6.1	1.6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
13	Bus 13	LV	1	1	0	1.050	-15.16	13.5	5.8	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
14	Bus 14	LV	1	1	0	1.036	-16.04	14.9	5.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0

-999

BRANCH DATA FOLLOWS

20 ITEMS

1	2	1	1	1	0	0.01938	0.05917	0.0528	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
1	5	1	1	1	0	0.05403	0.22304	0.0492	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	3	1	1	1	0	0.04699	0.19797	0.0438	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	4	1	1	1	0	0.05811	0.17632	0.0340	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	5	1	1	1	0	0.05695	0.17388	0.0346	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	4	1	1	1	0	0.06701	0.17103	0.0128	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	5	1	1	1	0	0.01335	0.04211	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	7	1	1	1	0	0.0	0.20912	0.0	0	0	0	0	0.978	0.0	0.0	0.0	0.0	0.0	0.0
4	9	1	1	1	0	0.0	0.55618	0.0	0	0	0	0	0.969	0.0	0.0	0.0	0.0	0.0	0.0
5	6	1	1	1	0	0.0	0.25202	0.0	0	0	0	0	0.932	0.0	0.0	0.0	0.0	0.0	0.0
6	11	1	1	1	0	0.09498	0.19890	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
6	12	1	1	1	0	0.12291	0.25581	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
6	13	1	1	1	0	0.06615	0.13027	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
7	8	1	1	1	0	0.0	0.17615	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
7	9	1	1	1	0	0.0	0.11001	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
9	10	1	1	1	0	0.03181	0.08450	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
9	14	1	1	1	0	0.12711	0.27038	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
10	11	1	1	1	0	0.08205	0.19207	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
12	13	1	1	1	0	0.22092	0.19988	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
13	14	1	1	1	0	0.17093	0.34802	0.0	0	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

-999

LOSS ZONES FOLLOWS

1 ITEMS

1 IEEE 14 BUS

-99

INTERCHANGE DATA FOLLOWS

1 ITEMS

1 2 Bus 2 HV 0.0 999.99 IEEE14 IEEE 14 Bus Test Case

-9

TIE LINES FOLLOWS

0 ITEMS

-999

END OF DATA



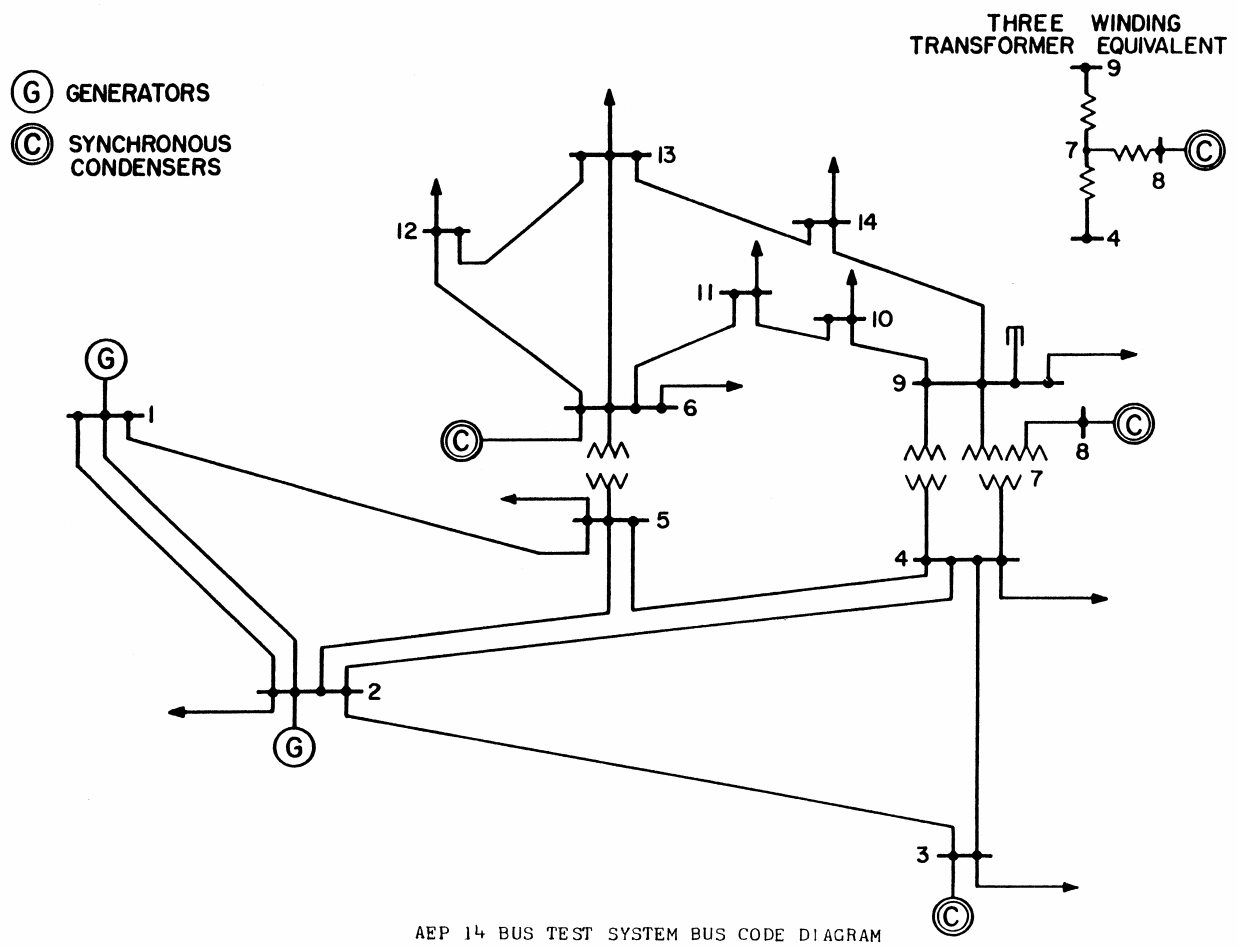


Figura 8.3: Sistema de 14 barras IEEE

## IEEE 30 BARRAS

```

08/20/93 UW ARCHIVE          100.0  1961 W IEEE 30 Bus Test Case
BUS DATA FOLLOWS
30 ITEMS
 1 Glen Lyn 132 1 1 3 1.060 0.0 0.0 0.0 260.2 -16.1 132.0 1.060 0.0 0.0 0.0 0.0 0
 2 Claytor 132 1 1 2 1.043 -5.48 21.7 12.7 40.0 50.0 132.0 1.045 50.0 -40.0 0.0 0.0 0
 3 Kumis 132 1 1 0 1.021 -7.96 2.4 1.2 0.0 0.0 132.0 0.0 0.0 0.0 0.0 0.0 0
 4 Hancock 132 1 1 0 1.012 -9.62 7.6 1.6 0.0 0.0 132.0 0.0 0.0 0.0 0.0 0.0 0
 5 Fieldale 132 1 1 2 1.010 -14.37 94.2 19.0 0.0 37.0 132.0 1.010 40.0 -40.0 0.0 0.0 0
 6 Roanoke 132 1 1 0 1.010 -11.34 0.0 0.0 0.0 0.0 132.0 0.0 0.0 0.0 0.0 0.0 0
 7 Blaine 132 1 1 0 1.002 -13.12 22.8 10.9 0.0 0.0 132.0 0.0 0.0 0.0 0.0 0.0 0
 8 Reusens 132 1 1 2 1.010 -12.10 30.0 30.0 0.0 37.3 132.0 1.010 40.0 -10.0 0.0 0.0 0
 9 Roanoke 1.0 1 1 0 1.051 -14.38 0.0 0.0 0.0 0.0 1.0 0.0 0.0 0.0 0.0 0.0 0
10 Roanoke 33 1 1 0 1.045 -15.97 5.8 2.0 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.19 0
11 Roanoke 11 1 1 2 1.082 -14.39 0.0 0.0 0.0 16.2 11.0 1.082 24.0 -6.0 0.0 0.0 0
12 Hancock 33 1 1 0 1.057 -15.24 11.2 7.5 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
13 Hancock 11 1 1 2 1.071 -15.24 0.0 0.0 0.0 10.6 11.0 1.071 24.0 -6.0 0.0 0.0 0
14 Bus 14 33 1 1 0 1.042 -16.13 6.2 1.6 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
15 Bus 15 33 1 1 0 1.038 -16.22 8.2 2.5 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
16 Bus 16 33 1 1 0 1.045 -15.83 3.5 1.8 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
17 Bus 17 33 1 1 0 1.040 -16.14 9.0 5.8 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
18 Bus 18 33 1 1 0 1.028 -16.82 3.2 0.9 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
19 Bus 19 33 1 1 0 1.026 -17.00 9.5 3.4 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
20 Bus 20 33 1 1 0 1.030 -16.80 2.2 0.7 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
21 Bus 21 33 1 1 0 1.033 -16.42 17.5 11.2 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
22 Bus 22 33 1 1 0 1.033 -16.41 0.0 0.0 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
23 Bus 23 33 1 1 0 1.027 -16.61 3.2 1.6 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
24 Bus 24 33 1 1 0 1.021 -16.78 8.7 6.7 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.043 0
25 Bus 25 33 1 1 0 1.017 -16.35 0.0 0.0 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
26 Bus 26 33 1 1 0 1.000 -16.77 3.5 2.3 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
27 Cloverdle 33 1 1 0 1.023 -15.82 0.0 0.0 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
28 Cloverdle132 1 1 0 1.007 -11.97 0.0 0.0 0.0 0.0 132.0 0.0 0.0 0.0 0.0 0.0 0
29 Bus 29 33 1 1 0 1.003 -17.06 2.4 0.9 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
30 Bus 30 33 1 1 0 0.992 -17.94 10.6 1.9 0.0 0.0 33.0 0.0 0.0 0.0 0.0 0.0 0
-999

```

```

BRANCH DATA FOLLOWS
41 ITEMS
 1 2 1 1 1 0 0.0192 0.0575 0.0528 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 1 3 1 1 1 0 0.0452 0.1652 0.0408 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 2 4 1 1 1 0 0.0570 0.1737 0.0368 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 3 4 1 1 1 0 0.0132 0.0379 0.0084 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 2 5 1 1 1 0 0.0472 0.1983 0.0418 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 2 6 1 1 1 0 0.0581 0.1763 0.0374 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 4 6 1 1 1 0 0.0119 0.0414 0.0090 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 5 7 1 1 1 0 0.0460 0.1160 0.0204 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 6 7 1 1 1 0 0.0267 0.0820 0.0170 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 6 8 1 1 1 0 0.0120 0.0420 0.0090 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 6 9 1 1 1 0 0.0 0.2080 0.0 0 0 0 0 0 0.978 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 6 10 1 1 1 0 0.0 0.5560 0.0 0 0 0 0 0 0.969 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 9 11 1 1 1 0 0.0 0.2080 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 9 10 1 1 1 0 0.0 0.1100 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
 4 12 1 1 1 0 0.0 0.2560 0.0 0 0 0 0 0 0.932 0.0 0.0 0.0 0.0 0.0 0.0 0.0
12 13 1 1 1 0 0.0 0.1400 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
12 14 1 1 1 0 0.1231 0.2559 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
12 15 1 1 1 0 0.0662 0.1304 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
12 16 1 1 1 0 0.0945 0.1987 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
14 15 1 1 1 0 0.2210 0.1997 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
16 17 1 1 1 0 0.0524 0.1923 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
15 18 1 1 1 0 0.1073 0.2185 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
18 19 1 1 1 0 0.0639 0.1292 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
19 20 1 1 1 0 0.0340 0.0680 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
10 20 1 1 1 0 0.0936 0.2090 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
10 17 1 1 1 0 0.0324 0.0845 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
10 21 1 1 1 0 0.0348 0.0749 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
10 22 1 1 1 0 0.0727 0.1499 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
21 22 1 1 1 0 0.0116 0.0236 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
15 23 1 1 1 0 0.1000 0.2020 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
22 24 1 1 1 0 0.1150 0.1790 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0
23 24 1 1 1 0 0.1320 0.2700 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0 0.0 0.0

```

```

24 25 1 1 1 0 0.1885 0.3292 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
25 26 1 1 1 0 0.2544 0.3800 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
25 27 1 1 1 0 0.1093 0.2087 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
28 27 1 1 1 0 0.0 0.3960 0.0 0 0 0 0 0 0.968 0.0 0.0 0.0 0.0 0.0
27 29 1 1 1 0 0.2198 0.4153 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
27 30 1 1 1 0 0.3202 0.6027 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
29 30 1 1 1 0 0.2399 0.4533 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
 8 28 1 1 1 0 0.0636 0.2000 0.0428 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
 6 28 1 1 1 0 0.0169 0.0599 0.0130 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
-999
LOSS ZONES FOLLOWS 1 ITEMS
 1 IEEE 30 BUS
-99
INTERCHANGE DATA FOLLOWS 1 ITEMS
-9
 1 2 Claytor 132 0.0 999.99 IEEE30 IEEE 30 Bus Test Case
TIE LINES FOLLOWS 0 ITEMS
-999
END OF DATA

```

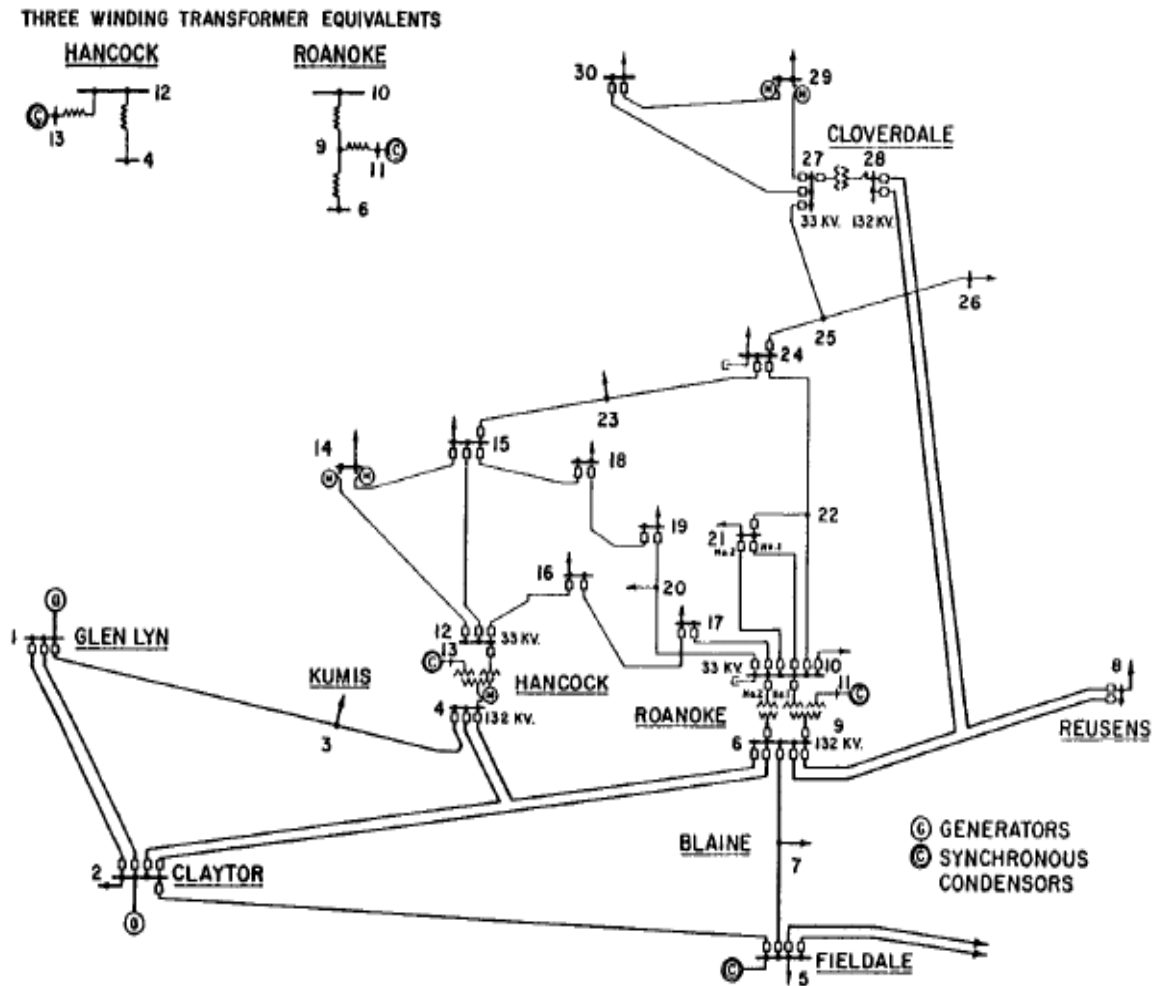


Figura 8.4: Sistema de 30 barras IEEE

## IEEE 57 BARRAS

```

08/25/93 UW ARCHIVE          100.0  1961 W IEEE 57 Bus Test Case
BUS DATA FOLLOWS
57 ITEMS
 1 Kanawha   V1 1 1 3 1.040    0.0  55.0  17.0 128.9 -16.1  0.0  1.040  0.0    0.0  0.0  0.0  0
 2 Turner    V1 1 1 2 1.010   -1.18  3.0  88.0  0.0  -0.8  0.0  1.010  50.0  -17.0  0.0  0.0  0
 3 Logan     V1 1 1 2 0.985   -5.97  41.0  21.0  40.0  -1.0  0.0  0.985  60.0  -10.0  0.0  0.0  0
 4 Sprigg    V1 1 1 0 0.981   -7.32  0.0  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
 5 Bus 5     V1 1 1 0 0.976   -8.52  13.0  4.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
 6 Beaver Ck V1 1 1 2 0.980   -8.65  75.0  2.0  0.0  0.8  0.0  0.980  25.0  -8.0  0.0  0.0  0
 7 Bus 7     V1 1 1 0 0.984   -7.58  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
 8 Clinch Rv V1 1 1 2 1.005   -4.45  150.0  22.0  450.0  62.1  0.0  1.005  200.0  -140.0  0.0  0.0  0
 9 Saltville V1 1 1 2 0.980   -9.56  121.0  26.0  0.0  2.2  0.0  0.980  9.0    -3.0  0.0  0.0  0
10 Bus 10    V1 1 1 0 0.986  -11.43  5.0  2.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
11 Tazewell V1 1 1 0 0.974  -10.17  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
12 Glen Lyn V1 1 1 2 1.015  -10.46  377.0  24.0  310.0  128.5  0.0  1.015  155.0  -150.0  0.0  0.0  0
13 Bus 13    V1 1 1 0 0.979   -9.79  18.0  2.3  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
14 Bus 14    V1 1 1 0 0.970   -9.33  10.5  5.3  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
15 Bus 15    V1 1 1 0 0.988   -7.18  22.0  5.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
16 Bus 16    V1 1 1 0 1.013   -8.85  43.0  3.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
17 Bus 17    V1 1 1 0 1.017   -5.39  42.0  8.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
18 Sprigg    V2 1 1 0 1.001  -11.71  27.2  9.8  0.0  0.0  0.0  0.0    0.0  0.0  0.10  0
19 Bus 19    V2 1 1 0 0.970  -13.20  3.3  0.6  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
20 Bus 20    V2 1 1 0 0.964  -13.41  2.3  1.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
21 Bus 21    V3 1 1 0 1.008  -12.89  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
22 Bus 22    V3 1 1 0 1.010  -12.84  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
23 Bus 23    V3 1 1 0 1.008  -12.91  6.3  2.1  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
24 Bus 24    V3 1 1 0 0.999  -13.25  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
25 Bus 25    V4 1 1 0 0.982  -18.13  6.3  3.2  0.0  0.0  0.0  0.0    0.0  0.0  0.059  0
26 Bus 26    V5 1 1 0 0.959  -12.95  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
27 Bus 27    V5 1 1 0 0.982  -11.48  9.3  0.5  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
28 Bus 28    V5 1 1 0 0.997  -10.45  4.6  2.3  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
29 Bus 29    V5 1 1 0 1.010   -9.75  17.0  2.6  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
30 Bus 30    V4 1 1 0 0.962  -18.68  3.6  1.8  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
31 Bus 31    V4 1 1 0 0.936  -19.34  5.8  2.9  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
32 Bus 32    V4 1 1 0 0.949  -18.46  1.6  0.8  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
33 Bus 33    V4 1 1 0 0.947  -18.50  3.8  1.9  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
34 Bus 34    V3 1 1 0 0.959  -14.10  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
35 Bus 35    V3 1 1 0 0.966  -13.86  6.0  3.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
36 Bus 36    V3 1 1 0 0.976  -13.59  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
37 Bus 37    V3 1 1 0 0.985  -13.41  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
38 Bus 38    V3 1 1 0 1.013  -12.71  14.0  7.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
39 Bus 39    V3 1 1 0 0.983  -13.46  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
40 Bus 40    V3 1 1 0 0.973  -13.62  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
41 Tazewell V6 1 1 0 0.996  -14.05  6.3  3.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
42 Bus 42    V6 1 1 0 0.966  -15.50  7.1  4.4  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
43 Tazewell V7 1 1 0 1.010  -11.33  2.0  1.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
44 Bus 44    V3 1 1 0 1.017  -11.86  12.0  1.8  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
45 Bus 45    V3 1 1 0 1.036   -9.25  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
46 Bus 46    V3 1 1 0 1.050  -11.89  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
47 Bus 47    V3 1 1 0 1.033  -12.49  29.7  11.6  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
48 Bus 48    V3 1 1 0 1.027  -12.59  0.0  0.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
49 Bus 49    V3 1 1 0 1.036  -12.92  18.0  8.5  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
50 Bus 50    V3 1 1 0 1.023  -13.39  21.0  10.5  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
51 Bus 51    V3 1 1 0 1.052  -12.52  18.0  5.3  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
52 Bus 52    V5 1 1 0 0.980  -11.47  4.9  2.2  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
53 Bus 53    V5 1 1 0 0.971  -12.23  20.0  10.0  0.0  0.0  0.0  0.0    0.0  0.0  0.063  0
54 Bus 54    V5 1 1 0 0.996  -11.69  4.1  1.4  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
55 Saltville V5 1 1 0 1.031  -10.78  6.8  3.4  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
56 Bus 56    V6 1 1 0 0.968  -16.04  7.6  2.2  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
57 Bus 57    V6 1 1 0 0.965  -16.56  6.7  2.0  0.0  0.0  0.0  0.0    0.0  0.0  0.0  0
-999
BRANCH DATA FOLLOWS
80 ITEMS
 1  2  1  1  1  0  0.0083  0.0280  0.1290  0  0  0  0  0  0.0  0.0  0.0  0.0  0.0  0.0  0
 2  3  1  1  1  0  0.0298  0.0850  0.0818  0  0  0  0  0  0.0  0.0  0.0  0.0  0.0  0.0  0
 3  4  1  1  1  0  0.0112  0.0366  0.0380  0  0  0  0  0  0.0  0.0  0.0  0.0  0.0  0.0  0
 4  5  1  1  1  0  0.0625  0.1320  0.0258  0  0  0  0  0  0.0  0.0  0.0  0.0  0.0  0.0  0
 4  6  1  1  1  0  0.0430  0.1480  0.0348  0  0  0  0  0  0.0  0.0  0.0  0.0  0.0  0.0  0
 6  7  1  1  1  0  0.0200  0.1020  0.0276  0  0  0  0  0  0.0  0.0  0.0  0.0  0.0  0.0  0

```



```

57 56 1 1 1 0 0.1740 0.2600 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
38 49 1 1 1 0 0.1150 0.1770 0.0030 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
38 48 1 1 1 0 0.0312 0.0482 0.0 0 0 0 0 0 0.0 0.0 0.0 0.0 0.0 0.0
9 55 1 1 1 0 0.0 0.1205 0.0 0 0 0 0 0 0.940 0.0 0.0 0.0 0.0 0.0
-999
LOSS ZONES FOLLOWS 1 ITEMS
1 IEEE 57 BUS
-99
INTERCHANGE DATA FOLLOWS 1 ITEMS
-9
1 8 Clinch Rv V1 0.0 999.99 IEEE57 IEEE 57 Bus Test Case
TIE LINES FOLLOWS 0 ITEMS
-999
END OF DATA

```

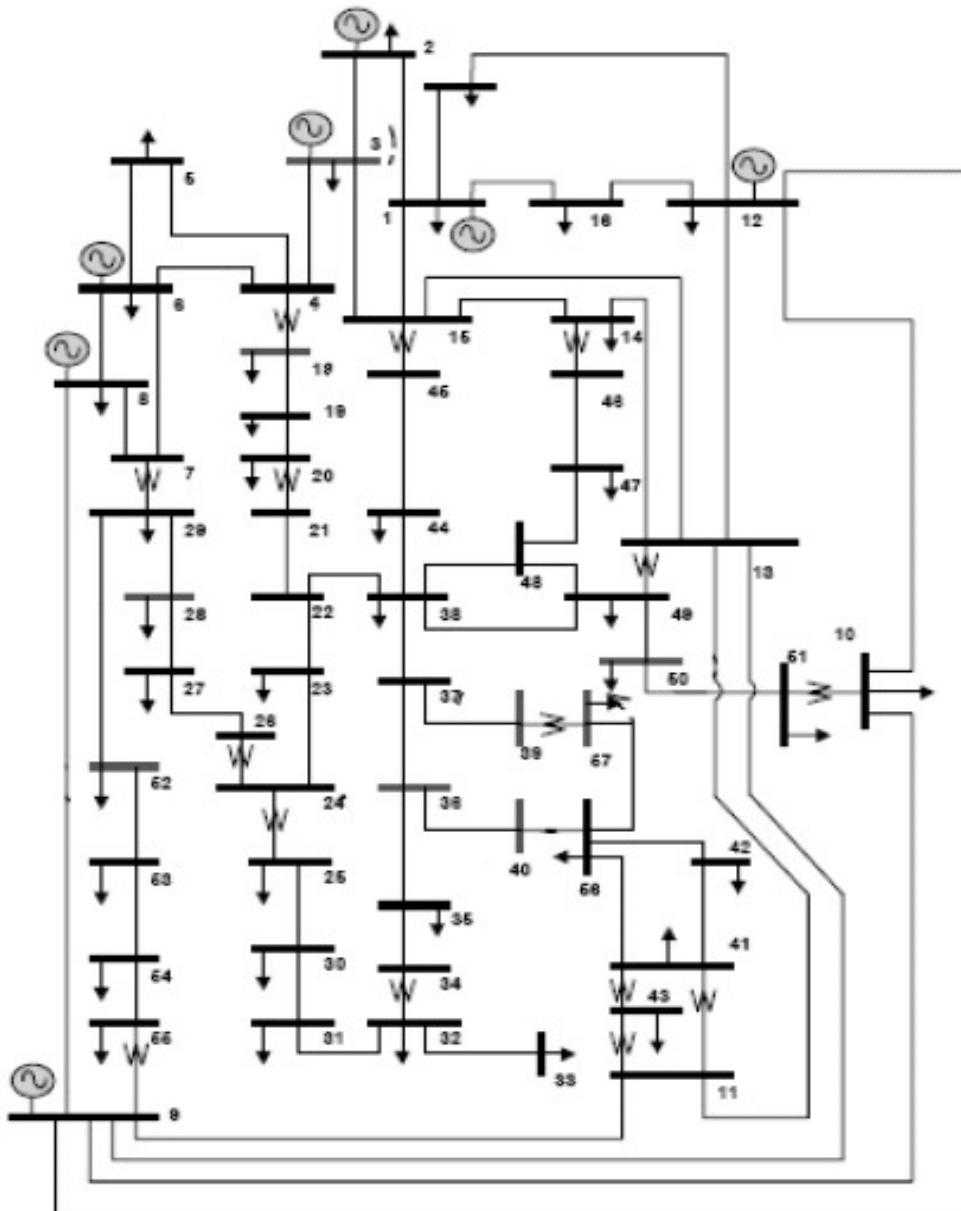


Figura 8.5: Sistema de 57 barras IEEE [30]

## Referências Bibliográficas

- [1] Arrillaga, J; Arnold, C. P. and Harker, B. J (1991). *Computer Analysis of Power Systems*, John Wiley & Sons.
- [2] Stott, B (1974). Review of load-flow calculation methods, *IEEE Proceedings*, vol. 62.
- [3] Braz, L. M. C; Castro, C. A. and Murari, C. A. F (2000). A Critical Evaluation of Step Size Optimization Based Load Flow Methods, *IEEE Transactions on Power Systems*, vol.15, n.1.
- [4] El-Sharkawi, M. and Niebur, D (1996). Artificial Neural Networks with Applications to Power Systems, *IEEE PES Special Publication 96*, TP 112-0.
- [5] Haykin, S (1998). *Neural Networks: a comprehensive foundation*, 2nd.ed., Prentice Hall.
- [6] Arquivos com os sistemas de potência modelo IEEE e figuras, disponível em:  
<http://www.ee.washington.edu/research/pstca/>
- [7] D. J. Sobajic and Yoh-Han Pao (1989). Artificial Neural-Net based Dynamic Security Assesment for Electric Power Systems, , *IEEE Transactions on Power Systems*, vol.4, no. 1, February.
- [8] Battiti, R (1992). First and Second-Order Methods for Learning: Between Steepest Descent and Newton's Method, *Neural Computation*, vol.4, n.2.
- [9] Mori, H (1992). Quadratic load flow calculation in electric power systems using a Hopfield model, *Proceedings of ICANN '92*, Brighton, U.K.
- [10] Hagan, M. T. and Menhaj, M. B (1994). Training feed-forward networks with the Marquardt algorithm, *IEEE Transactions on Neural Networks*, vol.5, n.6.
- [11] Nguyen, T.T (1995). Neural network load-flow, *IEE Proc. - Generation, Transmission and Distribution*, vol.142, n.1.
- [12] Cooke, M. J.; Lebby, G. L. (1998). An optimal design method for multilayer feedforward networks, *System Theory. Proceedings of the Thirtieth Southeastern Symposium*, on Volume, Issue,8-10 Mar 1998 Page(s):507 – 511. Digital Object Identifier 10.1109/SSST.1998.660125, vol.4, no. 1, February
- [13] Lo, K. L; Peng, L. J; Macqueen, J. F; Ekwue, A. O. and Cheng, D.T.Y (1998). Fast Real Power Contingency Ranking Using a Counter-propagation Network, *IEEE Transactions on Power Systems*, vol.13, n.4.

- [14] Refaee, J.A; Mohandes, M. and Maghrabi, H (1999). Radial Basis Function Networks for Contingency Analysis of Bulk Power Systems, *IEEE Transactions on Power Systems*, vol.14, no.2.
- [15] T. S. Chung and Fu Ying (1999). An ANN-based Network Equivalent Approach for Power System On-line Voltage Security Assesment. *IEEE Power Engineering Review*, October.
- [16] Paucar V. L. and Rider M. J (2000). Efficient Power Flow Initialization Using Artificial Neural Networks, IEEE 2000 Large Engineering Systems Conference on Power Engineering (LESCOPE 2000).
- [17] Paucar, V. L. and Rider, M. J (2002). Artificial Neural Networks for Solving the Power Flow Problem in Electric Power Systems, *Electric Power Systems Research*, vol.62, n.2.
- [18] Aleksander M. Stankovic, Andrija T. Saric and Mirjana Milosevic (2003). Identification of Nonparametric Dymanic Power System Equivalents With Artificial Neural Networks. *IEEE Transactions on Power Systems*, vol.18, no.14, NOVEMBER.
- [19] A. M. Azmy, I. Erlich and P. Sowa (2004). Identification of Nonparametric Dymanic Power System Equivalents With Artificial Neural Networks. *IEE Proc-Gener. Transm. Distrib.*, vol 151 no. 6, NOVEMBRO
- [20] Müller V. and Nelles D (2005). Artificial Neural Networks as Static Equivalent Networks. *IEE Proc. - Generation, Transmission and Distribution*, vol.152, n.1.
- [21] Müller, H. H.; Rider, Marcos Julio; Castro Junior, Carlos Alberto de; Paucar Casas, Vicente Leonardo; (2005). Power flow model using artificial neural networks, 06/2005, *International Conference – IEEE, St. Petersburg PowerTech*, Vol. 1, pp.1-6, St. Petersburg, Russia, Rússia.
- [22] Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr., V. L. Paucar. Cálculo de Fluxo de Carga por Redes Neurais Artificiais. In: VII Simpósio Brasileiro de Automação Inteligente (VII SBAI), 2005, São Luis - MA. Anais do VII SBAI, 2005.
- [23] <http://universe-review.ca/I10-40-nerve.jpg>, (2008)
- [24] A. Monticelli (1983). Fluxo de Carga em Redes de Energia Elétrica. Edgard Blücher.
- [25] Wang Y; da Silva L.C.P. and Xu W (2000). Investigation of the Relationship between Ill-Conditioned Power Flow and Voltage Collapse. *IEEE Power Engineering Review*.
- [26] T. J. Overbye, (1994). A power flow measure for unsolvable cases, *IEEE Transactions on Power Systems*, vol. 9, no. 3.



- [27] Tate J. E and Overbye T. J (2005). Comparison of the Optimal Multiplier in Polar and Rectangular Coordinates, *IEEE Transactions on Power Systems*, vol.20, no. 4.
- [28] Monticelli A; Deckmann S; Garcia A. and Stott B (1979). Real-Time External Equivalents for Static Security Analysis, *IEEE Transactions on Power Apparatus and Systems*, vol.PAS-98, n.2.
- [29] Tinney W.F. and Powell W.L (1977). *The REI Approach to Power Network Equivalents, Proc. PICA.*
- [30] I. C. Decker e R. S. Salgado. UFSC-CTC-EEL Trabalhos de Fluxo de Potência. (2007).

## Trabalhos afins publicados pela autora

Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr. Artificial Neural Networks for Load Flow and External Equivalents Studies, Paper submetido para *IET Generation, Transmission and Distribution*, 2008.

Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr., V. L. Paucar. Power flow model using artificial neural networks, *International Conference – IEEE, St. Petersburg PowerTech*, Vol. 1, pp.1-6, St. Petersburg, Russia, June 2005.

Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr., V. L. Paucar. Cálculo de Fluxo de Carga por Redes Neurais Artificiais. In: VII Simpósio Brasileiro de Automação Inteligente (VII SBAI), 2005, São Luis - MA. Anais do VII SBAI, 2005.

Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr., Fluxo de potência com controles de tensão baseado em redes neurais artificiais. FEEC-UNICAMP, SISPOT 2005.

Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr.. Fluxo de potência com controles de tensão baseado em redes neurais artificiais. FEEC-UNICAMP, SISPOT 2006.

Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr., Cálculo de Equivalentes Externos utilizando Redes Neurais Artificiais. FEEC-UNICAMP, SISPOT 2007.

Heloisa H. Müller, Marcos J. Rider, Carlos A. Castro Jr., Fluxo de Carga Neural Aplicado a Redes Mal Condicionadas. FEEC-UNICAMP, SISPOT 2007.